

Keskusteluaiheita

Discussion papers

Jukka Lassila

LINEAARISTEN SIMULTAANIYHTÄLÖ-
MALLIEN PARAMETRIEN ESTIMOINTI
RAJOITETUN INFORMAATION
MENETELMILLÄ

No 8

22.11.1976

This series consists of papers with limited circulation, intended to stimulate discussion. The papers must not be referred or quoted without the authors' permission



SISÄLLYSLUETTELO

	sivu
1. JOHDANTO	1
2. LINEAARINEN SIMULTAANIYHTÄLÖMALLI	3
2.1. Johdanto ja merkintöjä	3
2.2. Parametrien estimoinnissa tarvittava lisäinformaatio	7
2.2.1. Yleistä	7
2.2.2. Redusoidun muodon kertoimien estimointi	10
2.2.3. Eksogeenisten muuttujien kertoimien estimointi	11
2.2.4. Endogeenisten muuttujien kertoimien estimointi	12
3. ESTIMAATTORIEN JOHTAMINEN JA VERTAILU	16
3.1. Johdanto	16
3.2. Täsmälleen identifioituva yhtälö	18
3.3. Yli-identifioituva yhtälö	20
3.3.1. Lisäkriteerejä	20
3.3.2. Kerroinestimaattien neliösumman minimointi	21
3.3.3. Absoluuttisen lisäselityksen minimointi	23
3.3.4. Suhteellisen lisäselityksen minimointi	25
3.3.5. Identifiointirajoitusten testaaminen	27
3.4. k-luokan estimaattorit	29
3.5. Estimaattorien vertailu	32
3.5.1. Estimaattorien toimenkuvaukset	32
3.5.2. Estimaattorien vertailu	35
4. YHTEENVETO	40
5. PARAMETRIEN ESTIMOINTI ALAMITTAISISTA OTOKSISTA ..	45

TODISTUSLIITE

LÄHDELUETTELO

LINEAARISTEN SIMULTAANIYHTÄLÖMALLIEN PARAMETRIEN ESTIMOINTI
RAJOITETUN INFORMAATION MENETELMILLÄ

1. Johdanto

Ekonometristen mallien parametrien estimointiteorian tutkimuksesta on pääosan muodostanut ns. simultaaniyhtälöitä koskeva tutkimus. Simultaaniyhtälömalleissa useiden muuttujien arvot määräytyvät samanaikaisesti, ja jonkin yhtälön selittävä muuttuja voi olla toisissa yhtälöissä selittäjänä. Mallin määrittelystä riippuen saattavat estimointiongelmat vaihdella huomattavasti; hankaluuksia aiheuttavat esim. epälineaariset mallit ja monimutkaiset viivejakaumat sekä suurten mallien parametrien estimointi "alamittaisista" otoksista, jolloin havaintoja on vähemmän kuin eksogeenisiä selittäviä muuttujia.

Tässä tutkimuksessa tarkastellaan varsin yksinkertaista, useissa ekonometrian oppikirjoissa esitettyä mallia. Tässä mallissa, joka on täsmennetty luvussa 2, ei ole epälineaarisia osia eikä viivejakaukia. Viimeisessä luvussa mallia hieman vaikeutetaan: havaintoja oletetaan olevan vähemmän kuin eksogeenisiä muuttujia.

Tutkimuksen päätarkoituksena on selvittää, miten teoreettisen mallin sisältämää, erilaisista oletuksista koostuvaa informaatiota voidaan käyttää hyväksi estimaattoreita muodostettaessa, ja miten jotkut yleisesti tunnetut ja käytetyt estimaattorit tätä informaatiota käyttävät. Tutkimuksessa käsitellään

ainoastaan rajoitetun informaation menetelmiä; erona täyden informaation menetelmiin rajoitetun informaation menetelmät vaativat vain tarkasteltavan yhtälön spesifioimista, ei mallin kaikkien yhtälöiden. Rajoitetun informaationkin menetelmät vaativat kuitenkin tietoa siitä, mitä (eksogeenisiä) muuttujia sisältyy koko malliin.

Kaavoissa ja todistuksissa on käytetty matriisimerkintöjä. Lukemisen yksinkertaistamiseksi useimmat todistukset on siirretty liitteisiin. Todistukset on jaoteltu luvuittain.

Tutkimuksessa on kaksivaiheinen pienimmän neliösumman estimaattori ja rajoitetun informaation maximum likelihood-estimaattori johdettu aiemmasta hieman poikkeavalla tavalla. Luvussa 2 olevaa ehdollisen parhaan harhattoman estimaattorin teoreemaa en ole aiemmin nähnyt esitetyn; teoreema on yksinkertainen Aitkenin yleistetyn Gauss-Markov-teoreeman yleistys. Luvussa 3 esitettyä identifiointirajoitusten testaamista koskevia huomioita samoin kuin luvussa 5 esitettyä estimaattoria en ole aiemmin havainnut esitettyksi. Kaikki liitteissä esitetyt todistukset ovat omiani, joten niihin on suhtauduttava varauksellisesti.

2. LINEAARINEN SIMULTAANIYHTÄLÖMALLI

2.1. Johdanto ja merkintöjä

Tarkastellaan lineaarista yhtälöryhmää, jossa on M yhtälöä. Oletetaan, että yhtälöryhmässä on M kappaletta muuttujia y_1, \dots, y_M , joiden saamat arvot määräytyvät tarkasteltavassa yhtälöryhmässä ja riippuvat sekä toisistaan että yhtälöryhmässä olevien K :n muuttujan x_1, \dots, x_K saamista arvoista. Lisäksi y_i -muuttujien arvoihin vaikuttavat stokastiset virhetermit. Muuttujia y_i kutsutaan endogeenisiksi ja muuttujia x_i eksogeenisiksi muuttujiksi ja yhtälöryhmää malliksi. Jos oletetaan, että mallin muuttujista on T yhteistä havaintoa, voidaan mallin rakennemuoto esittää seuraavasti:

$$(2.1) \quad Y^* \Gamma = X\beta + U$$

Y^* on endogeenisten muuttujien $T \times M$ -havaintomatriisi, X vastaavasti eksogeenisten muuttujien $T \times K$ -havaintomatriisi. Γ ja β ovat tuntemattomien parametrien muodostamia kerroinmatriiseja, joiden dimensiot ovat $M \times M$ ja $K \times M$. Γ :n oletetaan olevan ei-singulaarinen. U on M :n $T \times 1$ -virhetermivektorin u_1, \dots, u_M muodostama tuntematon $T \times M$ -matriisi. Virhetermivektoreista oletetaan, että

$$(2.2) \quad E u_i = 0 \quad i = 1, \dots, M, \text{ ja}$$

$$(2.3) \quad E u_i u_j' = \sigma_{ij} I \quad i, j = 1, \dots, M.$$

Koska virhetermit ovat satunnaismuuttujia, ovat myös muuttujat y_i satunnaismuuttujia. Mallin redusoituun muotoon päästään kertomalla yhtälö (1) puolittain oikealta puolelta Γ :n käänteismatriisilla:

$$(2.4) \quad Y^* = X\beta\Gamma^{-1} + U\Gamma^{-1} \\ = X\Pi^* + V^*$$

Π^* on tuntemattomien parametrien muodostama $K \times M$ -matriisi ja V^* on virhetermimatriisi, joka koostuu vektoreista v_1, \dots, v_M . Voidaan osoittaa¹⁾, että

$$(2.5) \quad E v_i = 0 \quad i = 1, \dots, M, \text{ ja}$$

$$(2.6) \quad E v_i v_j = \omega_{ij} I \quad i, j = 1, \dots, M.$$

Rakennemuodon ja redusoidun muodon välillä ovat siis yhteydet

$$(2.7) \quad \beta\Gamma^{-1} = \Pi^*$$

$$(2.8) \quad U\Gamma^{-1} = V^*$$

Tässä tutkimuksessa ovat kiinnostuksen kohteena ns. rajoitetun informaation menetelmät, jolloin malli (1) estimoidaan yhtälö kerrallaan. Olkoon tyypillinen tarkasteltava yhtälö

1) kts. esim. Goldberger, A.S.: *Econometric Theory*, s. 301

$$(2.9) \quad y = Y\gamma + X_1\beta_1 + u$$

jossa y on varsinainen selitettävä muuttuja. Y on selittäjinä olevien endogeenisten muuttujien havaintomatriisi, X_1 on yhtälössä mukana olevien eksogeenisten muuttujien havaintomatriisi ja u on virhetermivektori. γ ja β_1 ovat tuntemattomia parametrivektoreita.

Voidaan olettaa, ilman että se vaikuttaa myöhempien tulosten yleisyyteen, että y on muuttuja y_1 , että Y on muuttujien y_2, \dots, y_M havaintomatriisi, dimensioiltaan $T \times (M-1)$, ja että X_1 on muuttujien x_1, \dots, x_{K_1} $T \times K_1$ havaintomatriisi. Tällöin γ on $(M-1) \times 1$ -vektori. u on muotoa $T \times 1$. Yhtälössä ovat siis mukana kaikki endogeeniset muuttujat, mutta eksogeenisistä muuttujista puuttuvat muuttujat x_{K_1+1}, \dots, x_K , joiden muodostamaa $T \times (K-K_1)$ -havaintomatriisia merkitään X_2 :lla. Sitä vastaava $(K-K_1) \times 1$ -parametrivektori β_2 on siis 0-vektori. Tällöin ovat voimassa ositukset

$$(2.10) \quad Y^* = [y \ Y] \quad \text{ja}$$

$$(2.11) \quad X = [X_1 \ X_2]$$

Muutkin tässä tutkimuksessa käytettävät ositukset noudattelevat jompaa kumpaa tai molempia edellä olevia osituksia.

Esimerkiksi V^* voidaan esittää kaavaa (10) vastaavasti

$$(2.12) \quad V^* = [v \quad v]$$

Π^* voidaan esittää kaavaa (10) vastaavasti

$$(2.13) \quad \Pi^* = [\pi \quad \Pi]$$

kaavaa (11) vastaavasti

$$(2.14) \quad \Pi^* = \begin{bmatrix} \Pi_1^* \\ \Pi_2^* \end{bmatrix} ;$$

tai molempia vastaavasti

$$(2.15) \quad \Pi^* = \begin{bmatrix} \pi_1 & \Pi_1 \\ \pi_2 & \Pi_2 \end{bmatrix}$$

Lisäksi otetaan käyttöön merkintä

$$(2.16) \quad \gamma^* = \begin{bmatrix} 1 \\ -\gamma \end{bmatrix}$$

γ^* -on siis $M \times 1$ -vektori. Yhtälö (9) voidaan nyt esittää muodossa

$$(2.17) \quad Y^* \gamma^* = X_1 \beta_1 + u$$

u :n varianssia merkitään tästä edes σ_u^2 :lla.

2.2. Parametrien estimoinnissa tarvittava lisäinformaatio

2.2.1. Yleistä

Estimaattori on havaintojen funktio, jonka kustakin otoksesta saaman arvon toivotaan olevan "lähellä" perusjoukon vastaavan parametrin arvoa. Tässä tutkittavassa tapauksessa, kuten yleensäkin, havainnot, ainakin osa niistä, ovat satunnaismuuttujien saamia arvoja. Tällöin estimaattori voidaan tulkita satunnaismuuttujien funktioksi ja se on siis itsekin satunnaismuuttuja.

Estimaattorin hyvyttä tarkastellaan usein mm. harhattomuuden ja konsistenssiuden käsitteiden avulla. Estimaattoria sanotaan harhattomaksi, jos sen odotusarvo on ko. parametrin arvo, ja konsistentiksi, jos todennäköisyys sille, että estimaattorin arvo poikkeaa ko. parametrin arvosta, lähestyy nollaa, kun havaintojen lukumäärä lähestyy ääretöntä. Estimaattorin ominaisuuksien tarkastelussa ovat tärkeitä myös estimaattorin varianssi ja asymptoottinen varianssi, joka on varianssin raja-arvo, kun havaintojen lukumäärä lähestyy ääretöntä.

Luvussa 2.1. esitettyjen tietojen avulla voitaisiin parametrit γ , β_1 ja Π^* estimoida, mutta tiedot eivät ole riittäviä estimaattorien edellämainittujen ominaisuuksien tutkimiseen. Estimaattoreiden ominaisuuksien kannalta ovat ratkaisevia tiedot tai oletukset selittävien muuttujien ja virhetermien välisistä suhteista.

Asian selventämiseksi tehdään eräitä väliaikaisia olettamuksia yhtälöstä (9). Merkitään $Z = [Y X_1]$ ja $\alpha = \begin{bmatrix} \gamma \\ \beta_1 \end{bmatrix}$. Tällöin Z on $T \times (M-1+K_1)$ ja α on $(M-1+K_1) \times 1$ -matriisi ja yhtälö (9) saa muodon

$$(2.18) \quad y = Z\alpha + u$$

Oletetaan (väliaikaisesti), että

$$(2.19) \quad E(u|Z) = \mu_Z, \text{ ja}$$

$$(2.20) \quad E(uu'|Z) = \sigma^2 W_Z,$$

eli virhetermien ehdollisen odotusarvon ja ehdollisen varianssin ehdolla Z oletetaan riippuvan Z :sta, eli virhetermit ja selittävät muuttujat eivät ole riippumattomia.

Tarkastellaan nyt y :n ja μ_Z :n suhteen ehdollisesti lineaarisia estimaattoreita ehdolla Z ¹⁾. Tällaiset estimaattorit ovat muotoa

$$(2.21) \quad \hat{\alpha} = C'y + D'\mu_Z$$

jossa C ja D ovat $T \times (M-1+K_1)$ -matriiseja. Todistusliitteessä on osoitettu, että estimaattorien ehdollinen harhattomuus ehdolla Z edellyttää, että

1) Ilman ehdollistamista estimaattorit olisivat yleensä stokastisia funktioita, eivätkä lineaarisia. Vrt. Goldberger, m.t., s. 268

$$(2.22) \quad C = -D ,$$

ja että näistä ehdollisesti harhattomista estimaattoreista pienin ehdollinen varianssi on estimaattorilla

$$(2.23) \quad a = (Z'W_Z^{-1}Z)^{-1}Z'W_Z^{-1}Y - (Z'W_Z^{-1}Z)^{-1}Z'W_Z^{-1}\mu_Z$$

Jälkimmäinen tulos on yleistys Aitkenin yleistetystä Gauss-Markov-teoreemasta¹⁾; olettamalla Z ei-stokastiseksi ja μ_Z nolllaksi, voidaan ehdollistamisesta luopua ja tulokseksi saadaan Aitkenin esittämä teoreema.

Estimaattoria (23) voitaisiin pitää varsin hyvänä estimaattorina, oletettavasti sen asymptoottisetkin ominaisuudet olisivat hyviä. Huomattakoon, että harhattomuus ei vaadi tietoja W_Z :sta, vaan ainoastaan μ_Z :sta. Yleensä μ_Z :sta ei kuitenkaan ole tietoa muulloin kuin silloin, kun se voidaan olettaa nolllaksi. Simultaaniyhtälömallien tapauksessa ei tällaista oletusta kuitenkaan voida tehdä, koska se on epälooginen endogeenisten muuttujien kohdalla; sen sijaan eksogeenisten muuttujien kohdalla olettaus voidaan tehdä ja yleensä tehdäänkin.

Tässä tutkimuksessa oletetaan, että muuttujat x_1, \dots, x_K ovat ei-stokastisia ja virhetermien odotusarvojen ei oleteta riippuvan niistä, eli

$$(2.24) \quad E(U|X) = E(U) = 0$$

1) Vrt. Goldberger, m.t., s. 233.

ja

$$(2.25) \quad E(V^*|X) = E(V^*) = 0 .$$

Yhtälön (9) estimointia varten voidaan yhtälöstä (24) havaita, että

$$(2.26) \quad E(u|X_1) = 0 .$$

Lisäksi oletetaan, että $x_1 \equiv 1$, eli myös vakio on selittävänä muuttujana.

Seuraavaksi tarkastellaan parametrien Π^* , β_1 ja γ estimointia käytettävissä olevan informaation avulla.

2.2.2. Redusoidun muodon kertoimien estimointi

Parametrimatriisi Π^* voidaan estimoida yhtälöstä (4)

$$(4) \quad Y^* = X\Pi^* + V^*$$

tavallisella pienimmän neliösumman menetelmällä (tästä eteenpäin PNS-menetelmällä). Yhtälö (4) sisältää M yhtälöä; estimointi tapahtuu yhtälö kerrallaan. Voidaan osoittaa, että Π^* :n estimaattori P^* :n on Π^* :n paras harhaton lineaarinen estimaattori¹⁾

1) kts. esim. Goldberger, m.t., s. 246-248.

ts. kaikista Π^* :n harhattomista estimaattoreista sillä on pienin varianssi.

$$(2.27) \quad P^* = (X'X)^{-1}X'Y^*$$

P^* voidaan osittaa samoin kuin Π^* :

$$(2.28) \quad P^* = [p \ P] = \begin{bmatrix} P_1^* \\ P_2^* \end{bmatrix} = \begin{bmatrix} p_1 & P_1 \\ p_2 & P_2 \end{bmatrix}$$

2.2.3. Eksogeenisten muuttujien kertoimien estimointi

Koska X on oletettu ei-stokastiseksi, voidaan μ_z kaavasta (19) merkitä seuraavasti

$$(2.29) \quad \mu_z = E(u|Z) = E(u|Y) = \mu_y$$

Se on kuitenkin edelleen tuntematon, eikä β_1 :n estimaattorina voida käyttää kaavan (23) estimaattorin a β_1 :tä vastaavaa osaa. Liitteessä on todistettu, että jos voitaisiin olettaa μ_y :n olevan lineaarinen Y :n suhteen, eli muotoa Y_k , jossa k on tuntematon $(M-1) \times 1$ -vektori, saataisiin PNS-menetelmällä β_1 :lle ehdollisesti harhaton estimaattori ehdolla Y . Koska aiemmin on oletettu, että $W_Z = E(uu'|Z) = \sigma_u^2 I$, olisi saatu estimaattori ehdollisesti paras harhaton lineaarinen estimaattori ehdolla Y ; lineaarinen tässä tapauksessa y :n ja μ_y :n suhteen.

β_1 :n estimointi ei kuitenkaan muodosta oleellista ongelmaa.

Kun tarkastellaan kaavaa (17):

$$(2.17) \quad Y^* \gamma^* = X_1 \beta_1 + u$$

havaitaan, että kaikki klassisen lineaarisen regressioanalyysin olettamukset ovat voimassa¹⁾, kun tulkitaan $Y^* \gamma^*$ selitettäväksi muuttujaksi²⁾.

Täten β_1 :n paras harhaton lineaarinen ($Y^* \gamma^*$:n suhteen) estimaattori on PNS-estimaattori:

$$(2.30) \quad b_1 = (X_1' X_1)^{-1} X_1' Y^* \gamma^*$$

Vaikeutena on edelleen se, että γ^* :ä ei tunneta ja täten b_1 :tä ei voida kokonaan laskea. Käytännössä γ^* korvataan jollain estimaattorillaan; saatu β_1 :n estimaattori on tällöin paras harhaton estimaattori ehdolla $\hat{\gamma}^*$. Tarkasteltaessa yleisimpiä simultaanimallien estimaattoreita, kuten kaksivaiheista pienimmän neliösumman menetelmää (tästä edes 2VPNS) ja rajoitetun informaation maximum likelihood-menetelmää (RIML), havaitaan, että niissä β_1 :n estimaattori voidaan esittää muodossa (2.30) siten, että γ^* :n paikalla on sen estimaattori.

2.2.4. Endogeenisten muuttujien kertoimien estimointi

Sopivan estimaattorin löytäminen γ^* :lle on tarkasteltavan

1) vrt. Goldberger, m.t., s. 162.

2) Tätä tulkintaa on käyttänyt esim. Chow (1964).

yhtälön estimoinnin vaikein vaihe. Koska $E(u | Y)$ ei ole tunnettu, ei kaavassa (23) esitettyä estimaattoria voida käyttää. Virhetermin ehdollisesta odotusarvosta tiedetään kuitenkin sen verran, että se ei ole nolla; jos γ^* (eli varsinaisesti siis γ) estimoitaisiin PNS-menetelmällä yhdessä β_1 :n kanssa, saataisiin ainakin γ :n kohdalla ehdollisesti harhaisia estimaatteja.

γ^* :n estimointia varten tarvitaan siis lisää informaatiota. Ainoa toistaiseksi käyttämätön informaatio on tieto siitä, että $\beta_2 = 0$; $Y^*\gamma^*$ ei riipu X_2 :sta, eli muuttujista x_{K_1+1}, \dots, x_K ¹⁾. Voidaan helposti löytää useitakin muuttujia, joista $Y^*\gamma^*$ ei riipu: kaikki sellaiset muuttujat, joista mikään muuttujista y_i , $i = 1, \dots, M$, ei ole riippuvainen, ovat varmasti sellaisia, että jokainen endogeenisten muuttujien y_i lineaarikombinaatio on niistä riippumaton. Informaatio siitä, että β_2 on nollavektori, on kuitenkin tulkittavissa toisin. Mallin endogeenisistä muuttujista jokin tai jotkut riippuvat muuttujista x_{K_1+1}, \dots, x_K , mutta endogeenisten muuttujien tietty lineaarikombinaatio $Y^*\gamma^*$ ei riipu yhdestäkään muuttujista x_{K_1+1}, \dots, x_K . Tämä havaitaan ottamalla odotusarvot toisaalta yhtälöstä (4) ja toisaalta yhtälöstä (17):

$$(2.31) \quad E(Y^*) = E(X\Pi^*) + E(V^*) = X\Pi^* = X_1\Pi_1^* + X_2\Pi_2^*$$

$$(2.32) \quad E(Y^*\gamma^*) = [E(Y^*)]\gamma^* = E(X_1\beta_1) + E(u) = X_1\beta_1$$

1) Muunlaisesta lisäinformaatiosta kts. esim. Fisher (1959).

Tieto siitä, että $\beta_2 = 0$, on ratkaiseva γ^* :n estimoinnin kannalta. Kyseessä on itse asiassa $K - K_1$ erillistä tietoa; onko tämä määrä riittävä, riippuu siitä, montako endogeenistä muuttujaa tarkasteltavassa yhtälössä on. Tätä ns. identifiointi-ongelmaa tarkastellaan myöhemmin.

Yhtälöistä (31) ja (32) saadaan tunnetut yhteydet Π^* :n, γ^* :n β :n ($= \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix}$) välille:

$$(2.33) \quad \Pi_1^* \gamma^* = \beta_1$$

$$(2.34) \quad \Pi_2^* \gamma^* = \beta_2 = 0$$

Tarkastellaan seuraavaksi mielivaltaista endogeenisten muuttujien lineaarikombinaatiota $Y^* \alpha$, jossa α on $M \times 1$ -vektori. Oletetaan muuttuja $Y^* \alpha$ selitetyksi muuttujilla x_1, \dots, x_K , ja yhtälö estimoiduksi PNS-menetelmällä. Merkitään kerroinestimaattoria b_α :lla:

$$(2.35) \quad b_\alpha = (X'X)^{-1} X'Y^* \alpha$$

Estimaattori voidaan osittaa kuten β :kin:

$$(2.36) \quad b_\alpha = \begin{bmatrix} b \\ \alpha_1 \\ b_{\alpha 2} \end{bmatrix}$$

Koska PNS-estimaattori on selitettävän muuttujan suhteen

lineaarinen, havaitaan, että¹⁾

$$(2.37) \quad b_{\alpha} = P^* \alpha ,$$

jossa P^* on aiemmin määritelty Π^* :n estimaattori. Yhtälö (2.37) voidaan nyt osoittaa seuraavasti:

$$(2.38) \quad P_1^* \alpha = b_{\alpha 1}$$

$$(2.39) \quad P_2^* \alpha = b_{\alpha 2}$$

Yhtälöiden (2.33) ja (2.34) kanssa analogiset yhtälöt olisivat voimassa, jos $b_{\alpha 2}$ olisi nollavektori. Tuntuisikin luonnolliselta pyrkiä löytämään sellainen α , joka samalla olisi γ^* :n estimaattori, että $b_{\alpha 2}$ olisi nollavektori tai "mahdollisimman lähellä" sitä. Jatkossa osoitetaankin, että tavallisimmat simultaanimalleissa käytetyt rajoitetun informaation estimaattorit, 2VPNS ja RIML, voidaan johtaa suoraan tästä tavoitteesta. Huomattakoon, että triviaaliratkaisu $\alpha = 0$ ei kelpaa, sillä merkinnän (2.16) mukaan γ^* :n ylin elementti on ykkönen.

1) Näitä PNS-estimaattoreiden lineaarikombinaatioita olen tarkastellut tutkimuksessani "Rakennuskustannusten ennustemalli", kansantaloustieteen pro gradu-työ Helsingin yliopistossa, toukokuu 1975.

3. ESTIMAATTORIEN JOHTAMINEN JA VERTAILU

3.1. Johdanto

Tarkasteltava yhtälö on siis

$$(3.1) \quad Y^* \gamma^* = X_1 \beta_1 + u \quad \text{eli}$$

$$(3.2) \quad y - Y\gamma = X_1 \beta_1 + u .$$

Ongelmana on γ^* :n eli varsinaisesti γ :n estimoiminen; β_1 :n estimointi ei muodosta sen jälkeen ongelmaa. γ :n estimointia varten on käytettävissä $K - K_1$ kappaletta informaatiota siitä, että muuttujien y_1, \dots, y_M lineaarikombinaatio $Y^* \gamma^*$ ei ole riippuvainen muuttujista x_{K_1+1}, \dots, x_K , vaikka jokaisesta x -muuttujasta on ainakin yksi y -muuttuja riippuvainen.

Yhtälö (3.1) on identifioituva jos redusoidun muodon kerroinmatriisista Π^* voidaan johtaa yhtälön (3.1) parametrit yksikäsitteisesti. Välttämätön ja riittävä ehto tälle on, että matriisin Π_2^* asteluku on $M-1$. Tämä on ns. rank-ehto¹⁾.

Koska Π^* on tuntematon, on ns. järjestysehto (order condition²⁾) käytännössä tärkeämpi; sen mukaan välttämätön ehto (3.1):n identifioituvuudelle on se, että mallissa mukana olevien, mutta yhtälöstä (3.1) puuttuvien eksogeenisten muuttujien lukumäärä on vähintään yhtä suuri kuin yhtälössä (3.1) selittäjinä olevien

1) kts. esim. Goldberger, mt. s.316

2) Goldberger, mt. s.316

endogeenisten muuttujien lukumäärä, eli että $K - K_1 \geq M - 1$.

Kun $K - K_1 = M - 1$, yhtälöä (3.1) sanotaan täsmälleen identifioituvaksi. On huomattava, että tässä tilanteessa informaatiota on "lukumääräisesti" yhtä paljon kuin jos virhetermin ehdollinen odotusarvo kaavassa (1.19) tunnettaisiin; ehdollisessa odotusarvossa on kysymys $M - 1 + K_1$:n muuttujan vaikutuksesta virhetermiin, nyt taas on käytettävissä $M - 1$ riippumattomuustietoa sen lisäksi, että aikaisemmin oletettiin, että K_1 muuttujaa x_1, \dots, x_{K_1} eivät vaikuta virhetermiin.

Myöhemmin osoitetaan, että informaation määrä on tällöin juuri riittävä: γ^* :n estimaattori c^* voidaan johtaa redusoidun muodon kerroinmatriisin estimaattorista P^{*1}).

Kun $K - K_1 > M - 1$, yhtälöä sanotaan yli-identifioituvaksi. Tällöin informaatiota on tavallaan liikaa. Tämä informaatio on siinä mielessä ristiriitaista, että γ :n estimaattoria c ei suoraan voida johtaa P^* :stä. Tarvitaan siis jotain kriteeriä tai periaatetta tämän liian suuren informaatiomäärän käyttämiseksi, tavallaan painottamiseksi, mielekkäällä tavalla; myöhemmin osoitetaan, miten eri kriteereillä päädytään eri estimaattoreihin.

Ellei erikseen toisin sanota, tarkastellaan tilannetta, jossa $K < T$, eli mallissa on eksogeenisiä muuttujia vähemmän kuin havaintoja. Luvun 3.5. lopussa vertaillaan estimaattoreita

1) Tällöin on oletettu, että P^* on "täyttä astetta", eli $\text{rank}(P^*) = \min(K, M)$.

tilanteessa $K = T$, ja luvussa 5 tarkastellaan tilannetta $K > T$.

3.2. Täsmälleen identifioituva yhtälö

Kuten luvussa 2.2.4. todettiin, luonnolliselta tuntuva $\gamma^*:n$ estimaattori α on sellainen, että yhtälössä

$$(1.39) \quad P_2^* \alpha = b_{\alpha 2}$$

olisi $b_{\alpha 2}$ nollavektori, tai "lähellä" sitä. Merkitään tästä edes $\alpha:n$ sijasta $c^*:llä$ $\gamma^*:n$ estimaattoria. Yhtälö (1.39) saa muodon

$$(3.3) \quad P_2^* c^* = b_{c^* 2}$$

c^* voidaan osittaa seuraavasti:

$$(3.4) \quad c^* = \begin{bmatrix} 1 \\ -c \end{bmatrix}$$

Tällöin (3.3) voidaan osittaa:

$$(3.5) \quad p_2 = P_2 c^* = b_{c^* 2}$$

Havaitaan, että

$$(3.6) \quad b_{c^* 2} = 0 \iff P_2 c^* = p_2$$

Täsmälleen identifioituvassa yhtälössä P_2^* on $(M - 1) \times M$ -matriisi, joten P_2 on $(M - 1) \times (M - 1)$ -matriisi. Se on yleensä ei-singulaarinen, joten b_{c^*2} saadaan nolllaksi asettamalla

$$(3.7) \quad c = P_2^{-1} p_2$$

Käyttämällä ositetun matriisin käänteismatriisin kaavaa¹⁾ c voidaan esittää muodossa

$$(3.8) \quad c = [D^{-1} X_2' M_1 Y]^{-1} D^{-1} X_2' M_1 Y \\ = (X_2' M_1 Y)^{-1} D D^{-1} X_2' M_1 Y \\ = (X_2' M_1 Y)^{-1} X_2' M_1 Y$$

jossa

$$(3.9) \quad M_1 = I - X_1 (X_1' X_1)^{-1} X_1'$$

$$(3.10) \quad D = X_2' M_1 X_2$$

Täsmälleen identifioituvassa tapauksessa, kun muuttujaa $Y^*c^* = y - Yc$ selitetään muuttujilla x_1, \dots, x_K ja yhtälö estimoidaan PNS-menetelmällä, saa muuttujien x_{K_1+1}, \dots, x_K kerroinvektorin β_2 estimaattori b_{c^*2} vapaasti määräytyessään arvon nollla, kuten yhtälöistä (3.6) ja (3.7) havaitaan.

1) kts. Goldberger, mt., s.174

β_1 :n estimaattori on

$$(3.11) \quad b_1 = (X_1'X_1)^{-1}X_1'(y-Yc)$$
$$= (X_1'X_1)^{-1}X_1'[I - Y(X_2'M_1Y)^{-1}X_2'M_1]y$$

3.3. Yli-identifioituva yhtälö

3.3.1. Lisäkrityerejä

Yli-identifioituvassa tapauksessa ei c :tä voida ratkaista kuten yhtälössä (3.7), sillä P_2 on singulaarinen, koska se ei ole edes neliömatriisi. Yleensä ei ole olemassa sellaista vektoria c , että b_{c*2} olisi nollavektori yhtälössä (3.5). Tällöin täytyy pyrkiä siihen, että löytyisi c , jolle b_{c*2} olisi "mahdollisimman lähellä" nollavektoria. Seuraavassa on esitetty kolme ehkä helpoimmin mieleen tulevaa kriteeriä:

1^o Minimoidaan β_2 :n kerroinestimaattien neliösumma, eli valitaan c siten, että $b_{c*2}'b_{c*2}$ minimoituu.

Saadulla γ :n estimaattorilla on eräitä epätyydyttäviä ominaisuuksia, kuten myöhemmin huomataan.

2^o Valitaan c siten, että selitettäessä muuttujaa $y - Yc$ ensin muuttujilla x_1, \dots, x_{K_1} ja lisättäessä sen jälkeen selittäjiksi x_{K_1+1}, \dots, x_K , jälkimmäisten muuttujien mukaantulon aiheuttama selitetyn varianssin absoluuttinen lisäys on mahdollisimman pieni, kun yhtälö estimoidaan PNS-menetelmällä. Toisin sanoen,

minimoidaan X_2 :n mukaantulon aiheuttama selitetyn varianssin absoluuttinen lisäys. Osoittautuu, että tällöin päädytään kaksivaiheiseen PNS-estimaattoriin (2VPNS).

3^o Minimoidaan X_2 :n mukaantulon aiheuttaman selitetyn varianssin lisäyksen suhde jäännösvarianssiin. Saatu estimaattori minimoi myös todennäköisyyden sille, että selitettäessä $y - Yc$:tä sekä muuttujille x_1, \dots, x_{K_1} että muuttujille x_{K_1+1}, \dots, x_K käyttäen PNS-menetelmää, β_2 :n estimaattori poikkeaa nolasta, kun virhetermin oletetaan noudattavan normaalijakaumaa. Osoittautuu, että tällöin päädytään rajoitetun informaation maximum likelihood-estimaattoriin (RIML).

3.3.2. Kerroinestimaattien neliösumman minimointi

Neliösumman minimointi tapahtuu normaalisti: sen ensimmäinen derivaatta c :n suhteen asetetaan nolaksi. Neliösumma on kaavan (3.5.) perusteella

$$(3.12) \quad b'_{c*2} b_{c*2} = (p_2 - P_2 c)' (p_2 - P_2 c) = p_2' p_2 - 2p_2' P_2 c + c' P_2' P_2 c$$

Derivoidaan neliösumma c :n suhteen:

$$(3.13) \quad \frac{\partial b'_{c*2} b_{c*2}}{\partial c} = -2 P_2' p_2 + 2 P_2' P_2 c ,$$

joka asetettuna nolaksi antaa "normaalilyhtälöt"

$$(3.14) \quad P_2' P_2 c = P_2' p_2$$

josta saadaan ratkaisu

$$(3.15) \quad c = (P_2' P_2)^{-1} P_2' p_2$$

Saatu ratkaisu on minimi, sillä

$$(3.16) \quad \frac{\partial^2 b_{c*2}^b}{\partial c^2} = 2P_2' P_2$$

joka on positiivisesti definiitti¹⁾.

Saatu estimaattori voitaisiin luultavasti osoittaa konsistentiksi²⁾.

Estimaattori on kuitenkin sikäli epätyytyttävä, että se riippuu muuttujien x_{K_1+1}, \dots, x_K mittayksiköistä.

P_2 :n elementtithän ovat näitä muuttujia vastaavia redusoidun muodon kerroinestimaattoreita ja niiden saamat arvot riippuvat muuttujien mittayksiköistä. Esimerkiksi muuttujan havaintojen kertominen vakiolla aiheuttaa sen, että vastaava kerroinestimaatti tulee jaetuksi vakiolla. Tällöin kerroinestimaattien neliösumma on suuresti riippuvainen muuttujien x_{K_1+1}, \dots, x_K mittayksiköistä. Mahdollinen korjauskeino olisi kyseiden eksogeenisten muuttujien normeeraaminen jakamalla ne keskihajonnoillaan.

1) vrt. Goldberger, s. 36, kaava 7.7. P_2 on $(K - K_1) \times (M - 1)$ -matriisi, ja $\text{rank}(P_2) = M - 1$.

2) tekemällä eräitä lisäolettamuksia. vrt. Goldberger, mt., s. 301

Kaava (3.15) saa auki kirjoitettuna muodon

$$(3.17) \quad c = (Y'M_1X_2D^{-1}D^{-1}X_2'M_1Y)^{-1}Y'M_1X_2D^{-1}D^{-1}X_2'M_1Y$$

β_1 :n estimaattori saadaan jälleen kaavasta (1.30).

3.3.3. Absoluuttisen lisäselityksen minimointi

Otetaan aluksi käyttöön eräitä lyhentäviä merkintöjä. Selitetään muuttujaa Y^*c^* PNS-menetelmää käyttäen muuttujilla x_1, \dots, x_{K_1} ja x_{K_1+1}, \dots, x_K . Merkitään kokonaisneliösummaa K :lla, eli

$$(3.18) \quad K = c^* 'Y' Yc^* = (y - Yc)' (y - Yc)$$

Merkitään selitettyä neliösummaa $S(X)$:llä

$$(3.19) \quad S(X) = c^* 'Y' X(X'X)^{-1} X' Yc^*$$

Merkitään jäänösneliösummaa $J(X)$:llä

$$(3.20) \quad J(X) = c^* 'Y' [I - X(X'X)^{-1} X'] Yc^*$$

Kun Y^*c^* :ä selitetään vain muuttujilla x_1, \dots, x_{K_1} , merkitään selitettyä neliösummaa $S(X_1)$:llä jne. Koska $x_1 \equiv 1$, tiedetään, että

$$(3.21) \quad K = S(X) + J(X) \\ = S(X_1) + J(X_1)$$

Merkitään lisäselitystä $S(X) - S(X_1)$ $L(X_2)$:lla;

$$(3.22) \quad L(X_2) = S(X) - S(X_1)$$

$L(X_2)$ on auki kirjoitettuna

$$(3.23) \quad L(X_2) = c^* Y^* M_1 X_2 D^{-1} X_2^* M_1^* Y^* c^*$$

Minimoidaan nyt (3.23) c^* :n suhteen. Menettelytapa on sama kuin luvussa 3.3.2. Tulokseksi saadaan

$$(3.24) \quad c = (Y^* H Y)^{-1} Y^* H y$$

jossa

$$(3.25) \quad H = M_1 X_2 D^{-1} X_2^* M_1^*$$

Liitteessä on johdettu kaava (3.24) ja todistettu, että tulos on minimi. β_1 :n estimaattori on tällöin

$$(3.26) \quad b_1 = (X_1^* X_1)^{-1} X_1^* [I - Y(Y^* H Y)^{-1} Y^* H] y$$

1) vrt. Goldberger, s. 176-177.

Liitteessä on osoitettu, että b_1 ja c ovat itse asiassa β_1 :n ja γ :n kaksivaiheisen pienimmän neliösumman estimaattorit. Täten niiden ominaisuudet ovat hyvin tunnettuja. Ominaisuuksia käsitellään luvussa 3.5.

3.3.4. Suhteellisen lisäselityksen minimointi

Edellisessä luvussa minimoitiin absoluuttinen lisäselitys $L(X_2)$, nyt minimoidaan lisäselityksen suhde jäännösneliösummaan, eli lauseke $\frac{L(X_2)}{J(X)}$. Minimointi tapahtuu c :n suhteen. Minimoitava lauseke on auki kirjoitettuna seuraava:

$$(3.27) \quad \frac{L(X_2)}{J(X)} = \frac{c^* ' Y^* ' H Y^* c^*}{c^* ' Y^* ' M Y^* c^*} ,$$

jossa

$$(3.28) \quad M = I - X(X'X)^{-1}X'$$

Voidaan osoittaa¹⁾, että (3.27) saa minimin, kun ratkaistaan yhtälö

$$(3.29) \quad (H - \lambda M)c^* = 0$$

ja valitaan pienintä ominaisarvoa λ vastaava ominaisvektori c^* . Tämän jälkeen käytetään ns. normalisointisääntöä, eli

1) kts. esim. Wonnacott-Wonnacott, *Econometrics*, s. 376-378.

tietoa siitä, että c^* :n ylimmän alkion on oltava ykkönen. Ilman tätä sääntöä c^* saataisiin vain vakiokerrointa vaille. Huomattakoon, että lausekkeen (3.27) minimiarvo on juuri pienin λ^1 .

β_1 :n estimaattori on jälleen muotoa

$$(3.30) \quad b_1 = (X_1'X_1)^{-1}X_1'Y^*c^*$$

Seuraavaksi osoitetaan, että saadut estimaattorit minimoivat todennäköisyyden sille, että β_2 :n estimaattori b_{c^*2} poikkeaisi merkittävästi nolasta, kun Y^*c^* :tä ajatellaan selitetyn kaikilla x_i -muuttujilla $i = 1, \dots, K$.

Oletetaan, että virhetermit noudattavat normaalijakaumaa, ja että $Eu = 0$ ja $Euu' = \sigma_u^2 I$. Tällöin sen hypoteesin vallitessa, että $\beta_2 = 0$, noudattaa testisuure²⁾

$$(3.31) \quad \frac{T-K}{K-K_1} \cdot \frac{Q_2}{J(X)}$$

F-jakaumaa vapausastein $\frac{K - K_1}{T - K}$, jossa

$$(3.32) \quad Q_2 = b_2'Db_2 = c^*Y^*HY^*c^*$$

Suuret testisuureen arvot antavat aihetta epäillä hypoteesin $\beta_2 = 0$ oikeellisuutta. On selvää, että estimaattori, joka

1) vrt. Wonnacott-Wonnacott, mt., s.378

2) vrt. Goldberger, mt., s.177.

minimoi lausekkeen (3.27), minimoi myös lausekkeen (3.31).

Liitteessä on todistettu, että edellä esitetyt β_1 :n ja γ :n estimaattorit ovat itse asiassa rajoitetun informaation maximum likelihood-estimaattoreita. Näiden estimaattoreiden ominaisuudet ovat tunnetut. Niitä käsitellään luvussa 3.5.

3.3.5. Identifiointirajoitusten testaaminen

Tähän asti on oletettu, että muuttuja $Y^* \gamma^*$ on riippumaton muuttujista x_{K_1+1}, \dots, x_K . Tätä oletusta voidaan myös testata. Ekonometrian oppikirjoissa¹⁾ on yleisesti esitetty käytettäväksi testisuuretta $(\hat{\lambda} - 1)$, joka itse asiassa on

$$(3.33) \quad \hat{\lambda} - 1 = \lambda,$$

jossa λ on pienin ominaisarvo yhtälöstä (3.29) kuten liitteessä on todistettu. $(\hat{\lambda} - 1)$:n voidaan osoittaa noudattavan asympotoottisesti jakaumaa $\chi_{K-K_1-M+1}^2$, jos identifiointirajoitus on oikea.

Kuten luvussa 3.3.4. osoitettiin, noudattaa testisuure

$$(3.31) \quad \frac{T-K}{K-K_1} \lambda = \frac{T-K}{K-K_1} (\hat{\lambda} - 1)$$

F-jakaumaa vapausastein $\frac{K}{T} - \frac{K_1}{K_1}$, jos identifiointirajoitus on

1) kts. esim. Goldberger, m.t., s. 346.

oikea. Jos testisuure joutuu hylkäämisalueelle, tiedetään, että jokaiselle lineaarikombinaatiolle $Y^*\alpha$, jossa α :n ylin alkio on ykkönen, testisuure joutuu hylkäämisalueelle: λ saatiin minimoimalla lauseke, joka samalla minimoi ko. testisuureen. Jos minimikin on liian suuri, ovat varmasti kaikki muutkin testisuureen saamat arvot liian suuria. Identifiointirajoitus $\beta_2 = 0$ voidaan silloin hylätä ja vaihtoehtoinen hypoteesi $\beta_2 \neq 0$ astuu voimaan.

Basmann¹⁾ on johtanut vastaavan testisuureen 2VPNS-estimaattoria käytettäessä. Hänen mukaansa testisuure

$$(3.32) \quad \frac{T-K}{K-K_1-M+1} \cdot \frac{c^* 'Y^* 'HY^* c^*}{c^* 'Y^* 'MY^* c^*}$$

jossa c^* on γ^* :n 2VPNS-estimaattori, noudattaa approksimatiivisesti F-jakaumaa vapausasteilla $K-K_1 - M+1$ ja $T-K$. Testisuure voidaan esittää neliösummalyhenteiden avulla muodossa

$$(3.33) \quad \frac{T-K}{K-K_1-M+1} \cdot \frac{L(X_2)_{2VPNS}}{J(X)_{2VPNS}}$$

jossa alaviite 2VPNS viittaa siihen, että c^* on 2VPNS-estimaattori.

Theilin²⁾ mukaan Basmannin menetelmä on Monte Carlo-kokeissa osoittautunut χ^2 -menetelmää paremmaksi.

1) Basmann (1960).

2) Theil: Principles of Econometrics, s. 508.

2VPNS-menetelmän yhteydessä voitaisiin myös ajatella ehdollista F-testiä: ehdolla, että γ^* :n 2VPNS-estimaattori c^* on oikea, testataan, poikkeako muuttujia x_{K_1+1}, \dots, x_K vastaavan kerroinvektorin β_2 estimaattori b_{c^*2} merkitsevästi nolasta, kun muuttujaa Y^*c^* selitetään muuttujilla x_1, \dots, x_K , ja yhtälö estimoidaan PNS-menetelmällä. Testisuure

$$(3.34) \quad \frac{T-K}{K-K_1} \cdot \frac{L(X_2)_{2VPNS}}{J(X)_{2VPNS}}$$

noudattaa F-jakaumaa parametrein $K - K_1$ ja $T - K$, kun identifiointirajoitukset ovat voimassa.

Kaikissa eo. testimenettelyissä on oletettu virhetermin noudattavan normaali jakaumaa.

3.4. k-luokan estimaattorit

Ennen kuin siirrytään estimaattoreiden vertailuun, laajennetaan tarkasteltavien estimaattoreiden ryhmää yksiparametrillä estimaattoriperheellä, k-luokan estimaattoreilla. Tämän Theilin kehittämän estimaattoriryhmän normaaliyhtälöt voidaan esittää muodossa¹⁾

$$(3.35) \quad (Y'Y - k\hat{V}'\hat{V})c_k + Y'X_1b_k = Y'y - k\hat{V}'y$$

$$(3.36) \quad X_1'Yc_k + X_1'X_1b_k = X_1'y$$

1) vrt. Goldberger, m.t., s. 336.

jossa

$$(3.37) \quad \hat{V}'y = Y' [I - X(X'X)^{-1}X']y = Y'My$$

$$(3.38) \quad \hat{V}'\hat{V} = Y'MY$$

$$(3.39) \quad b_k = (X_1'X_1)^{-1}X_1'(y - Yc_k)$$

(3.35) voidaan esittää seuraavasti:

$$(3.40) \quad Y' [I - kI + kX(X'X)^{-1}X']Yc_k + Y'X_1b_k = Y' [I - kI + kX(X'X)^{-1}X']y$$

Sijoittamalla tähän (3.39) saadaan

$$(3.41) \quad Y' [I - kI + kX(X'X)^{-1}X' - X_1(X_1'X_1)^{-1}X_1']Yc_k \\ = Y' [I - kI + kX(X'X)^{-1}X' - X_1(X_1'X_1)^{-1}X_1']y$$

Tästä saadaan edelleen

$$(3.42) \quad Y' \{ (1-k) [I - X_1(X_1'X_1)^{-1}X_1'] + k [X(X'X)^{-1}X' - X_1(X_1'X_1)^{-1}X_1'] \} Yc_k \\ = Y' \{ (1-k) [I - X_1(X_1'X_1)^{-1}X_1'] + k [X(X'X)^{-1}X' - X_1(X_1'X_1)^{-1}X_1'] \} y$$

Toisaalta

$$(3.43) \quad X'(X'X)^{-1}X' - X_1(X_1'X_1)^{-1}X_1' = M_1X_2D^{-1}X_2'M_1 \quad 1) \\ = H \quad 2)$$

1) vrt. Goldberger, m.t., s. 174 ja 176.

2) vrt. kaava (3.25).

joten (3.42) saa muodon

$$(3.44) \quad Y' [(1-k)M_1 + kH]Yc_k = Y' [(1-k)M_1 + kH]Y$$

jossa $M_1 = I - X_1(X_1'X_1)^{-1}X_1'$ eli c_k on

$$(3.45) \quad c_k = \{Y' [(1-k)M_1 + kH]Y\}^{-1} Y' [(1-k)M_1 + kH]Y$$

(3.44) on auki kirjoitettuna

$$(3.46) \quad (1-k)Y'M_1Yc_k + kY'HYc_k \\ = (1-k)Y'M_1Y + kY'HY$$

Toisaalta kaavaan (3.44), päästään minimoimalla c_k :n suhteen lauseke

$$(3.47) \quad (1-k)(y-Yc_k)'M_1(y-Yc_k) + k(y-Yc_k)'H(y-Yc_k) \\ \Leftrightarrow (1-k)J(X_1) + kL(X_2)$$

kuten liitteessä on todistettu. Täten k-luokan estimaattori saadaan minimoimalla (3.46) c_k :n suhteen ja laskemalla b_k kaavasta (3.39).

3.5. Estimaattorien vertailu

3.5.1. Estimaattorien toimenkuvaukset

Seuraavassa pyritään vertailemaan toisiinsa erilaisia γ :n estimaattoreita c . Kaikki β_1 :n estimaattorithan osoittautuivat olevan tavallisia PNS-estimaattoreita, kun muuttujaa $y - Yc$ selitetään muuttujilla x_1, \dots, x_{K_1} . Tästä seuraa, että onpa c saatu millä tahansa menetelmistä 2VPNS, RIML, k-luokan estimaattorimenetelmä tai PNS, jossa siis c ja b_1 on estimoitu yht'aikaa, on voimassa neliösummahajoitelma:

$$(3.48) \quad K = S(X_1) + J(X_1) \quad (\text{kts. luku 3.3.3})$$

Samoin on voimassa, että jos $(y - Yc)$:tä olisi PNS-menetelmällä selitetty kaikilla x_i -muuttujilla $i = 1, \dots, K$, niin

$$(3.49) \quad K = S(X) + J(X)$$

Toisaalta kaavan (3.22) mukaan

$$(3.22) \quad L(X_2) = S(X) - S(X_1)$$

jolloin kaavoista (3.47), (3.48) ja (3.22) päästään kaavaan

$$(3.50) \quad J(X_1) - L(X_2) = J(X)$$

Kaikki neliösummat kaavassa (3.49) ovat c^* :n (eli c :n) funktioita. Estimaattorin toimenkuvaukseksi kutsutaan tästä

eteempäin jonkin neliösumman minimoimista $c:n$ suhteen. PNS-estimaattorin toimenkuvaus on luonnollisesti

$$(3.51) \quad \text{PNS: } \min_c J(X_1)$$

Luvun 3.3.3. mukaan 2VPNS:n toimenkuvaus on ¹⁾

$$(3.52) \quad \text{2VPNS: } \min_c L(X_2)$$

Luvun 3.3.4. mukaan RIML:n toimenkuvaus on

$$(3.53) \quad \text{RIML: } \min_c \frac{L(X_2)}{J(X)}$$

Luvun 3.5 mukaan k -luokan estimaattorin toimenkuvaus on

$$(3.54) \quad \text{k-luokka: } \min_c (1-k)J(X_1) + kL(X_2)$$

eli k -luokan estimaattorin toimenkuvaus on painotettu keskiarvo PNS:n ja 2VPNS:n toimenkuvauksista²⁾, painoina $(1 - k)$ ja k . Tästä ei seuraa, että k -luokan estimaattori olisi painotettu keskiarvo PNS- ja 2VPNS-estimaattoreista.

-
- 1) Teoksessa Wonnacott-Wonnacott, m.t., mainitaan s. 381, että 2VPNS minimoi jäännösvariانسien erotuksen $J(X_1) - J(X)$; tämähän on yhtä kuin $L(X_2)$.
 - 2) Teoksessa Wonnacott-Wonnacott, m.t., osoitetaan s. 379, että k -luokan estimaattori voidaan tulkita instrumenttimuuttuja-menetelmäksi, jossa instrumenttimuuttuja on painotettu keskiarvo PNS:n ja 2VPNS:n instrumenttimuuttujista.

Yhdistettynä estimaattorien toimenkuvaukset ovat siis seuraavat:

(3.55)

Estimaattori	minimoi c:n suhteen	tavoitefunktion
PNS		$J(X_1)$
2VPNS		$L(X_2)$
RIML		$\frac{L(X_2)}{J(X)}$
k-luokan estimaattori		$(1-k)J(X_1) + k L(X_2)$

Kaikki tavoitefunktiot ovat kvadraattisia c:n funktioita.

Kolme ensimmäistä tavoitefunktiota voi saada vain ei-negatiivisia arvoja. Huomattakoon, että RIML:iä ei voida laskea, kun $J(X) = 0$.

Yllä olevat tavoitefunktiot voidaan luonnollisesti esittää useissa eri muodoissa käyttämällä hyväksi yhtälöitä (3.21) ja (3.22).

3.5.2. Estimaattorien vertailu

Estimaattorien vertailu tapahtuu pääasiassa taulukon (3.55) avulla. Aluksi vertaillaan estimaattorien keskinäisiä suhteita eri tilanteissa ja lopuksi yleisesti. Eri tilanteissa havaintojen, poissa- ja mukana olevien eksogeenisten muuttujien sekä endogeenisten muuttujien lukumäärät vaihtelevat. Muistettakoon, että tutkimuksessa on oletettu mallien kaikkien endogeenisten muuttujien olevan mukana tarkastelussa yhtälössä. Oletus ei sinänsä ole tärkeä eikä vähennä todistusten yleisyyttä. Jos kaikki endogeeniset muuttujat eivät ole mukana, on luvun M-1 paikalle seuraavassa tarkastelussa asetettava yhtälössä selittäjinä olevien endogeenisten muuttujien lukumäärä.

1^o Tarkastellaan täsmälleen identifioituvaa yhtälöä, eli $K - K_1 = M - 1$, ja oletetaan, että $K < T$. Luvun 3.2. perusteella tiedetään, että muuttujia x_{K_1+1}, \dots, x_K vastaavat regressiokerrotoimet voidaan saada nolliksi. Täten luvussa 3.2. esitetty ratkaisu minimoi sekä 2VPNS:n että RIML:n tavoitefunktion, eli nämä estimaattorit yhtyvät luvussa 3.2. esitettyyn estimaattoriin, jota kutsutaan epäsuoraksi PNS-estimaattoriksi.

Kuten tunnettua, 2VPNS-estimaattori on k-luokan estimaattori k:n avulla 1, ja RIML on k-luokan estimaattori k:n arvolla $\lambda + 1$. Tässä tapauksessa λ' saa arvon 0, joten 2VPNS, RIML ja k-luokan estimaattori $k = 1$ yhtyvät.

2^o Tarkastellaan yli-identifioituvaa yhtälöä, eli $K - K_1 > M - 1$ jossa edelleen $K < T$.

Estimoidun yhtälön selityskykyä voidaan vertailla jäännösneliösumman $J(X_1)$ avulla. Tämä saa pienimmän arvonsa, kun käytetään PNS-estimaattoria. Seuraavaksi todistetaan, että 2VPNS:n jäännösneliösumma on pienempi kuin RIML:n jäännösneliösumma. Taulukosta (3.54) voidaan päätellä, että

$$(3.56) \quad \frac{L(X_2)_{RIML}}{J(X)_{RIML}} < \frac{L(X_2)_{2VPNS}}{J(X)_{2VPNS}}$$

ja että

$$(3.57) \quad L(X_2)_{RIML} > L(X_2)_{2VPNS} ,$$

josta seuraa

$$(3.58) \quad J(X)_{RIML} > J(X)_{2VPNS} ,$$

joka voidaan (3.49):n mukaan esittää muodossa

$$(3.59) \quad J(X_1)_{RIML} - L(X_2)_{RIML} > J(X_1)_{2VPNS} - L(X_2)_{2VPNS}$$

Tästä voidaan päätellä, että

$$(3.60) \quad J(X_1)_{RIML} - J(X_1)_{2VPNS} > L(X_2)_{RIML} - L(X_2)_{2VPNS} \\ > 0 .$$

Yhtälöiden selityskyvystä voidaan siis todeta, että

$$(3.61) \quad J(X_1)_{\text{PNS}} < J(X_1)_{2\text{VPNS}} < J(X_1)_{\text{RIML}}$$

3^o Seuraavaksi tarkastellaan tilannetta, jossa $K - K_1 > M - 1$ ja $K = T$. Tällöin $J(X) = 0$, eli $J(X_1) = L(X_2)$ kaikilla estimaattoreilla. Taulukosta (3.54) havaitaan, että

$$(3.62) \quad J(X) = 0 \Rightarrow \text{RIML ei ole olemassa}$$

(3.63) PNS = 2VPNS = k-luokan estimaattori kaikilla äärellisillä k:n arvoilla. RIML on tässä tapauksessa k-luokan estimaattori k:n arvolla ääretön.

4^o Lopuksi tarkastellaan tilannetta, jossa $K - K_1 = M - 1$ ja $K = T$. Kohdista 1^o ja 3^o voidaan päätellä, että

$$(3.64) \quad \text{RIML ei ole olemassa}$$

$$(3.65) \quad \text{PNS} = 2\text{VPNS} = k\text{-luokan estimaattori kaikilla } |k| < \infty$$

$$(3.66) \quad J(X_1)_{\text{PNS}} = J(X_1)_{2\text{VPNS}} = J(X_1)_k = 0$$

Eri estimaattorien toimenkuvaukset siis painottavat eri lailla yhtälön selityskykyä [eli termiä $J(X_1)$] ja rajoitusta $\Pi_2^* \gamma^* = 0$ [eli termiä $L(X_2)$]. k-luokan estimaattori painottaa selityskykyä painoa $(1-k)$ ja identifiointirajoitusta painolla k.

Täten

- PNS painottaa vain selityskykyä,
- 2VPNS painottaa vain identifiointirajoitusta,
- RIML painottaa yli-identifioituvassa tapauksessa, samoin kuin ne k-luokan estimaattorit, joilla $k > 1$, selityskykyä negatiivisesti ja identifiointirajoitusta yli 1:n suuruisella painolla.

Huomattakoon, että RIML on k-luokan estimaattori, jota vastaava k-luokan estimaattorin tavoitefunktion arvo on nolla. Jos merkitään λ_i :llä RIML:n laskemisessa saatua i:nnettä ominaisarvoa, voidaan päätellä, että k-luokan estimaattorin tavoitefunktio saa arvon nolla kaikilla k_i :

$$(3.67) \quad k_i = \lambda_i + 1$$

k-luokan estimaattorin tavoitefunktio voi saada myös negatiivisia arvoja. Tämä saattaa olla yhteydessä siihen, että tietyillä k:n arvoilla estimaattori "räjähtää".

2VPNS vaikuttaa monessa suhteessa miellyttävämmältä kuin RIML. Se on laskennallisesti yksinkertaisempi, selityskyky on yli-identifioituvassa tapauksessa parempi, se on olemassa tilanteissa 3^o ja 4^o eli tilanteissa, jossa $K = T$. Tällöin RIML ei ole olemassa. Jos RIML tulkitaan k-luokan estimaattoriksi, sen ominaisuus painottaa selityskykyä negatiivisesti vaikuttaa epäilyttävältä.

RIML vaikuttaa 2VPNS-estimaattoria käyttökelpoisemmalla ainoastaan identifiointirajoitusten testaamisessa.

Luvussa 3.3.2. esitetty estimaattori ei ole ollut vertailussa mukana. Tähän estimaattoriin palataan lyhyesti seuraavassa luvussa.

4. YHTEENVETO

Tutkimuksen tarkoituksena oli selvittää, miten teoreettisen mallin sisältämää, erilaisista oletuksista koostuvaa informaatiota voidaan käyttää hyväksi estimaattoreita muodostettaessa, ja miten eräät yleisesti tunnetut ja käytetyt estimaattorit tätä informaatiota käyttävät.

Aluksi tutkittiin virhetermien ja selittävien muuttujien keskinäistä riippuvuutta. Todettiin, että oleellista ei ole se, että virhetermit olisivat riippumattomia selittävästä muuttujasta, vaan se, että riippuvuus on tunnettu. Luvussa 2 esitettiin kaava hyvälle estimaattorille, kun virhetermin ehdollinen odotusarvo ja ehdollinen varianssi tunnetaan.

Kun virhetermit oletetaan riippumattomiksi eksogeenisistä muuttujista, ei redusoidun muodon parametrien estimoinnissa ole vaikeuksia. Myös β_1 :n estimointi on selväpiirteistä: tulkitaan Y^*c^* , jossa c^* on γ^* :n estimaattori, selitettäväksi muuttujaksi, ja estimoidaan β_1 tavallisella PNS-menetelmällä. Todettiin, että k-luokan estimaattorit, siis myös 2VPNS ja RIML, voidaan esittää tässä muodossa. Identifiointirajoitusten testaaminen voitiin myös palauttaa tavallisen klassisen regressioyhtälön kertoimia koskevien hypoteesien testaamiseen, kun Y^*c^* tulkittiin selitettäväksi muuttujaksi.

γ :n estimointia varten ei riittävää informaatiota virhetermien ja muuttujien y_i riippuvuuksista ole. Tämän sijasta käytettiin hyväksi olettamusta

$$(4.1) \quad \Pi_2^* \gamma^* = 0$$

joka voidaan myös esittää muodossa

$$(4.2) \quad \pi_2 = \Pi_2 \gamma$$

γ :n estimointi osoittautui olevan sellaisen vektorin c etsimistä, että yhtälö

$$(4.3) \quad p_2 = P_2 c$$

olisi "mahdollisimman hyvin" voimassa, kun p_2 ja P_2 ovat π_2 :n ja Π_2 :n PNS-estimaattoreita. Antamalla erilaisia operationaalaisia tulkintoja sanonnalle "mahdollisimman hyvin", päädytään erilaisiin estimaattoreihin.

γ :n estimointi on itse asiassa tavallista regressioanalyysiä, jossa redusoidun muodon estimaatit ovat havaintoja. Yhtälön (4.3) voidaan tulkita poikkeavan yhtälöstä (4.2) siinä mielessä, että muuttujien havainnoissa on mittausvirheitä. Tiedetään, että¹⁾

1) Vrt. Goldberger, mt., s. 174.

$$(4.4) \quad p_2 = \pi_2 + D^{-1} X_2' M_1 v$$

$$(4.5) \quad P_2 = \Pi_2 + D^{-1} X_2' M_1 V$$

josta seuraa

$$(4.6) \quad p_2 = P_2 \gamma + D^{-1} X_2' M_1 (v - V\gamma) = P_2 \gamma + \varepsilon$$

$$(4.7) \quad E\varepsilon = 0$$

$$(4.8) \quad E\varepsilon\varepsilon' = \sigma_\varepsilon^2 D^{-1} \quad (D = X_2' M_1 X_2)$$

Tällöin γ :n estimaattori c saadaan Aitkenin yleistetyllä pienimmän neliösumman menetelmällä¹⁾:

$$(4.9) \quad c = (P_2' D P_2)^{-1} P_2' D p_2$$

Sijoittamalla (4.9):ään p_2 :n ja P_2 :n lausekkeet ja sieventämällä saadaan

$$(4.10) \quad c = [Y' M_1 X_2 D^{-1} X_2' M_1 Y]^{-1} Y' M_1 X_2 D^{-1} X_2' M_1 p_2 \\ = (Y' H Y)^{-1} Y' H y$$

1) Vrt. Goldberger, mt., s. 232.

Havaitaan, että c on γ :n 2VPNS-estimaattori¹⁾. Se on konsistentti, vaikka virhetermit eivät olekaan riippumattomia selittävistä muuttujista (joiden havaintomatriisi on P_2).

Luvussa 3.3.2 johdettiin γ :lle estimaattori

$$(4.11) \quad c = (P_2'P_2)^{-1}P_2'p_2$$

joka on muuten samanlainen kuin kaavan (4.9) estimaattori, mutta se ei huomioi virhetermien kovarianssimatriisia. Jos virhetermit olisivat riippumattomia selittävistä muuttujista, jotka olisivat ei-stokastisia, olisi Aitkenin yleistetyn Gauss-Markov-teoreeman mukaan estimaattorilla (4.11) suurempi varianssi kuin estimaattorilla (4.9). Vaikka nämä olettamukset eivät ole voimassa, tuntuu (4.9) paremmalta estimaattorilta kuin (4.11).

Huomattakoon, että yhtälössä (4.6) on havaintoja $K-K_1$ kappaletta ja selittäviä muuttujia $M-1$ kappaletta. Vapausasteiden määrä $K-K_1-M+1$ mittaa samalla alkuperäisen tarkasteltavan yhtälön yli-identifioituvuuden määrää. Tästä havaitaan myös, että estimointi ei ole mahdollista ali-identifioituvassa tapauksessa.

1) Vrt. luku 3.3.3.

Intuitiivisen mielikuvan eri estimointimenetelmien toiminnasta eri tilanteissa saa tarkastelemalla estimaattoreiden toimenkuvauksia. Näiden toimenkuvausten avulla voidaan redusoidun muodon estimaatteja jossain määrin käyttää hyväksi myös rakennemuodon yhtälöitä spesifioitaessa. Ilmeiseltä virhespesifioinnilta esim. vaikuttaa tilanne, jossa rakennemuodon yhtälöstä on jätetty pois sellainen eksogeeninen muuttuja x_j , josta muuttuja y on redusoidun muodon estimaattien perusteella riippuvainen, mutta mikään mukaan otetuista endogeenisistä selittävästä muuttujista ei ole riippuvainen x_j :stä. Tällainen "poikkeava havainto" painottuu ilmeisesti merkittävästi kaikissa γ :n estimointimenetelmissä. Helpoimmin asia on ymmärrettävissä tarkastelemalla estimaattoria (4.11).

5. PARAMETRIEN ESTIMOINTI ALAMITTAISISTA OTOKSISTA

Aiemmissä luvuissa on oletettu, että mallissa on eksogeenisiä muuttujia vähemmän kuin havaintoja, eli $K < T$.

Luvussa 3.5 tarkasteltiin estimaattoreita myös tilanteessa $K = T$. Tällöin matriisi X on ei-singulaarinen ja Π^* :n estimaattori P^* on

$$(5.1) \quad P^* = X^{-1}Y^*$$

Kun $K > T$, ei redusoidun muodon kerroinmatriisia voida estimoida, eikä yhtään luvussa 3 esitellyistä γ :n estimaattoreista myöskään voida laskea. Tällaisessa tilanteessa otosta voidaan kutsua alamittaiseksi (undersized).

Useita alamittaisten otosten tapaukseen sopivia estimaattoreita on jo kehitetty¹⁾; monet näistä ovat iteratiivisia. Seuraavassa johdetaan yksinkertainen γ :n estimaattori, joka sopii tilanteeseen $K > T$.

Oletetaan, että moniulotteinen stationaarinen stokastinen prosessi generoi muuttujien x_1, \dots, x_K arvot (ts. hylätään olettamus muuttujien ei-stokastisuudesta). Virhetermien oletetaan olevan riippumattomia muuttujista x_i .

1) Kts. Dutta (1975).

Muuttujan $Y^* \gamma^*$ oletetaan edelleen olevan riippumaton muuttujista x_{K+1}, \dots, x_K . Riippumattomuudesta seuraa, että

$$(5.2) \quad \text{cov}(Y^* \gamma^*, x_i) = 0 \text{ kaikilla } i = K_1+1, \dots, K$$

Tällöin myös

$$(5.3) \quad E(X_2 - EX_2)' (Y^* \gamma^* - EY^* \gamma^*) = 0$$

eli

$$(5.4) \quad E(X_2 - EX_2)' (Y^* \gamma^* - X_1 \Pi_1^* \gamma^* - X_2 \Pi_2^* \gamma^*) = 0$$

eli

$$(5.5) \quad E(X_2 - EX_2)' (Y^* - X_1 \Pi_1^* \gamma^*) = 0$$

sillä edelleen on oletettu, että

$$(5.6) \quad \Pi_2^* \gamma^* = 0$$

EX_2 ja Π_1^* ovat tuntemattomia, mutta ne voidaan korvata estimaattoreillaan. EX_2 :n estimaattorina käytetään otoskeskiarvoista muodostettua matriisiä \bar{X}_2 , jonka tyypillinen alkio on

$$(5.7) \quad \{\bar{X}_2\}_{ij} = \frac{1}{T} \cdot x_{K+j}^i \cdot a_j^i$$

jossa siis a on $T \times 1$ -vektori, jonka alkiot ovat ykkösiä.

Merkitään

$$(5.8) \quad z_2 = x_2 - \bar{x}_2$$

Π_1^* :n estimaattorissa käytetään \tilde{P}_1^* :tä, joka on¹⁾

$$(5.9) \quad \tilde{P}_1^* = (X_1' X_1)^{-1} X_1' Y^*$$

Tällöin \tilde{P}_1^* voidaan osittaa samoin kuin Π_1^* :

$$(5.10) \quad \tilde{P}_1^* = [\tilde{p}_1 \tilde{P}_1]$$

\tilde{P}_1^* on yleensä harhainen estimaattori.

Yhtälön (5.5) vasemman puolen paikalle tulee nyt vastaava "otossuure"

$$(5.11) \quad z_2'(Y^* - X_1 \tilde{P}_1^*) \gamma^* = d$$

joka $(K - K_1) \times 1$ -vektori. Se ei ole nollavektori, mutta sen voisi olettaa olevan "lähellä" nollavektoria.

Vektori d voidaan osittaa seuraavasti:

$$(5.12) \quad d = z_2'(Y - X_1 \tilde{P}_1) - z_2'(Y - X_1 \tilde{P}_1) \gamma,$$

1) Oletetaan, että $K_1 < T$.

jossa on käytetty hyväksi $Y^*:n$, $\gamma^*:n$ ja $\tilde{P}_1^*:n$ osituksia.

(5.12) voidaan esittää muodossa

$$(5.13) \quad Z_2'(Y - X_1\tilde{P}_1) = Z_2'(Y - X_1\tilde{P}_1)\gamma + d$$

Yhtälö (5.13) on eräänlainen regressioyhtälö.

Merkitään

$$(5.14) \quad s = Z_2'(Y - X_1\tilde{P}_1)$$

$$(5.15) \quad R = Z_2'(Y - X_1\tilde{P}_1)$$

jossa s on $(K - K_1) \times 1$ -vektori ja R on $(K - K_1) \times (M - 1)$ - matriisi. Tällöin (5.13) saa muodon

$$(5.16) \quad s = R\gamma + d$$

Virhetermistä voidaan päätellä, että

$$(5.17) \quad E(d - Ed) \text{ on tuntematon ja}$$

$$(5.18) \quad E(d - Ed)(d - Ed)'$$
 on tuntematon.

γ :lle saadaan nyt estimaattori PNS-menetelmällä:

$$(5.19) \quad \hat{\gamma} = (R'R)^{-1}R's$$

Huolimatta siitä, että \hat{y} on harhainen eikä sillä liene mitään minimivarianssiin vivahtavia ominaisuuksia, se on ilmeisesti konsistentti. Olen yrittänyt osoittaa konsistenssiuden liitteessä. Konsistenssin mielekkyys tässä tapauksessa tuntuu kuitenkin kyseenalaiselta, koska siinä havaintojen määrän lähestyessä ääretöntä on myös $K < T$.

Monimutkaisista merkinnöistä huolimatta estimaattorin \hat{y} taustalla oleva ajatus on yksinkertainen: valitaan sellainen \hat{y} , että otoskovarianssit muuttujan $(y - Y\hat{y})$ ja muuttujien x_{K+1}, \dots, x_K välillä ovat "mahdollisimman lähellä" nollaa.¹ Kriteeriksi on valittu se, että otoskovarianssien neliösumma minimoituu. Muuttujan $(y - Y\hat{y})$ otoskovarianssi muuttujan x_j kanssa on hajotettu eri muuttujien y_i otoskovariansseiksi muuttujan x_j kanssa.

Muuttujien y_i otoskovarianssia x_j :n kanssa ei kuitenkaan ole laskettu y_i :n otoskeskiarvon avulla, vaan sen sijaan on käytetty termiä

$$(5.20) \quad (X_1'X_1)^{-1}X_1'y_i$$

Regressioyhtälössä (5.16) muuttujan s havainto j on ristitulo

$$(5.12) \quad \{s\}_j = (x_j - \bar{x}_j)' [y_1 - (X_1'X_1)^{-1}X_1'y_1]$$

ja matriisin R tyypillinen alkio on

$$(5.22) \quad \{R\}_{ji} = (x_j - \bar{x}_j)' [y_{i+1} - (X_1' X_1)^{-1} X_1' y_{i+1}]$$

Tästä havaitaan, että alkiot ja samalla myös estimaattori $\hat{\gamma}$ riippuu muuttujien x_j , $j=K_1+1, \dots, K$ mittayksiköistä. Tämä vika voidaan poistaa jakamalla muuttujien x_j arvot ko. muuttujan otoskeskihajonnalla.

Huomattakoon, että eo. estimaattori voidaan laskea kaikissa tapauksissa, joissa $K - K_1 > M - 1$ ja $K_1 < T$. Todella suurissa malleissa on vapausasteita $K - K_1 - M + 1$ luultavasti hyvin runsaasti. Käytännössä tämä lienee usein näennäistä, koska osa havainnoista on luultavasti lähellä nollavektoria, ts. mikään alkuperäisen yhtälön endogeenisistä muuttujista ei korreloi joidenkin muuttujien x_j kanssa.

Kun γ on estimoitu, voidaan β_1 :n estimaattorina jälleen käyttää estimaattoria

$$(5.23) \quad b_1 = (X_1' X_1)^{-1} X_1' (y - Y\hat{\gamma})$$

TODISTUSLIITE

Luku 2.2.1.

Tarkastellaan yhtälöä

$$(1) \quad y = Z\alpha + u, \text{ jossa}$$

$$(2) \quad E(u|Z) = \mu_Z$$

$$(3) \quad E[(u - Eu)(u - Eu)' | Z] = \sigma_u^2 W_Z, \text{ jossa } W_Z \text{ on positiivisesti definiitti.}$$

Tarkastellaan α :n estimaattoreita $\hat{\alpha}$, jotka ovat lineaarisia y :n ja μ_Z :n suhteen, eli

$$(4) \quad \hat{\alpha} = C'y + D'\mu_Z$$

Väite: a) jotta $\hat{\alpha}$ olisi harhaton ehdolla Z , täytyy olla

$$(5) \quad D' = -C' \quad \text{ja}$$

$$(6) \quad C'Z = I$$

b) ehdollisesti harhattomista estimaattoreista on pienin ehdollinen varianssi estimaattorilla

$$(7) \quad a = \tilde{C}'(y - \mu_Z) = (Z'W_Z^{-1}Z)^{-1}Z'W_Z^{-1}(y - \mu_Z)$$

Todistus:

$$\begin{aligned} (8) \quad E(\hat{\alpha}|Z) &= E[C'(Z\alpha + u) | Z] + ED'\mu_Z \\ &= C'Z\alpha + C'E(u|Z) + D'\mu_Z \\ &= C'Z\alpha + C'\mu_Z + D'\mu_Z \end{aligned}$$

Jotta $E(\hat{\alpha}|Z) = \alpha$, täytyy väitteen a)-kohdan olla voimassa.

Ehdollisesti harhattomille estimaattoreille on voimassa

$$(9) \quad [(\hat{\alpha} - \alpha) | Z] = C'u - C'\mu_Z = C'(u - \mu_Z)$$

$$(10) \quad E[(\hat{\alpha} - \alpha)(\hat{\alpha} - \alpha)' | Z] = C'\sigma_u^2 W_Z C = \sigma_u^2 C'W_Z C$$

Voidaan todeta, että estimaattori $\tilde{C}'(y - \mu_Z)$ kaavassa (7)

on ehdollisesti harhaton ja sen ehdollinen varianssi on

$$\begin{aligned}
 (11) \quad (\Sigma_{aa} | Z) &= \sigma_u^2 \check{C}' W_Z \check{C} \\
 &= \sigma_u^2 (Z' W_Z^{-1} Z)^{-1} Z' W_Z^{-1} W_Z W_Z^{-1} Z (Z' W_Z^{-1} Z)^{-1} \\
 &= \sigma_u^2 (Z' W_Z^{-1} Z)^{-1}
 \end{aligned}$$

Kaikki ehdollisesti harhattomat y :n ja μ_z :n suhteen lineaariset estimaattorit voidaan esittää muodossa

$$(12) \quad \hat{\alpha} = (\check{C}' + F')(y - \mu_z)$$

jossa ehdollisesta harhattomuudesta edelleen seuraa

$$(13) \quad F'Z = 0$$

Tällöin $\hat{\alpha}$:n ehdollinen varianssi on

$$\begin{aligned}
 (14) \quad (\Sigma_{\hat{\alpha}\hat{\alpha}} | Z) &= \sigma_u^2 | (\check{C}' + F') W_Z (\check{C} + F) | \\
 &= \sigma_u^2 (\check{C}' W_Z \check{C} + F' W_Z \check{C} + \check{C}' W_Z F + F' W_Z F) \\
 &= (\Sigma_{aa} | Z) + \sigma_u^2 F' W_Z F
 \end{aligned}$$

sillä

$$\begin{aligned}
 (15) \quad \check{C}' W_Z F &= (Z' W_Z^{-1} Z)^{-1} Z' W_Z^{-1} W_Z F \\
 &= (Z' W_Z^{-1} Z)^{-1} Z' F \\
 &= (Z' W_Z^{-1} Z)^{-1} 0 \\
 &= 0
 \end{aligned}$$

ja samoin myös $F' W_Z \check{C} = 0$.

Koska $F' W_Z F$ on ei-negatiivisesti definiitti, on b)-kohta todistettu.

Todistus on täysin analoginen Goldbergerin esittämän Aitkenin yleistetyn Gauss-Markov-teoreeman todistuksen kanssa (kts. Goldberger, mt., s. 232 - 233). Aitkenin teoreema saadaan erikoistapauksena tässä esitetystä teoreemasta.

Luku 2.2.3.

Väite: Jos edellisessä todistuksessa olisi kaavassa (2) ollut

$$(1) E(u|Z) = E(u|Y) = Yk,$$

saataisiin PNS-menetelmällä α :n X_1 :tä vastaavalle osalle β_1 ehdollisesti harhaton estimaattori

Todistus: Merkitään $m = \begin{bmatrix} k \\ 0 \end{bmatrix}$, jossa m on $(M-1+K_1) \times 1$ -vektori.

Tällöin

$$(2) Yk = Zm$$

Edellisen todistuksen kaavasta (8) voidaan päätellä, että estimaattorin

$$(3) a = (Z'Z)^{-1}Z'y$$

ehdollinen harha

$$(4) E(a|Z) = (Z'Z)^{-1}Z'Zm = m,$$

jonka β_1 :tä vastaava osa on nollavektori.

Luku 3.3.3.

Väite: $c = (Y'HY)^{-1}Y'Hy$ minimoi lausekkeen

$$(1) L(X_2) = (y-Yc)'H(y-Yc)$$

Todistus:

$$(2) \frac{\partial L(X_2)}{\partial c} = 2Y'HYc - 2Y'Hy$$

$$= 0 \Leftrightarrow Y'HYc = Y'Hy$$

$$\Leftrightarrow c = (Y'HY)^{-1}Y'Hy$$

Saatu tulos on minimi, kun

(3) $\frac{\partial^2 L(X_2)}{\partial c^2} = 2Y'HY$ on positiivisesti definiitti, eli kun $c'y'HYc > 0$ kaikilla $c \neq 0$. Tämä taas pitää paikkansa, kun selitettäväksi muuttujaksi tässä tapauksessa tulkittavaa Yc :tä vastaava X_2 :n mukanaan tuoma lisäselitys on >0 : näin voidaan olettaa yleisesti olevan.

Väite: Estimaattori $c = (Y'HY)^{-1}Y'Hy$ on γ :n ja estimaattori $b_1 = (X_1'X_1)^{-1}X_1'(Y-Yc)$ β_1 :n 2VPNS-estimaattori.

Todistus:

Lähdetään liikkeelle Goldbergerin esittämästä 2VPNS-estimaattorin kaavasta¹⁾:

$$(1) \begin{pmatrix} Y'X(X'X)^{-1}X'Y & Y'X_1 \\ X_1'Y & X_1'X_1 \end{pmatrix} \begin{pmatrix} \hat{\gamma} \\ \hat{\beta}_1 \end{pmatrix} = \begin{pmatrix} Y'X(X'X)^{-1}X'Y \\ X_1'Y \end{pmatrix}$$

Kirjoitetaan se auki:

$$(2) Y'X(X'X)^{-1}X'Y\hat{\gamma} + Y'X_1\beta_1 = Y'X(X'X)^{-1}X'Y$$

$$(3) X_1'Y\hat{\gamma} + X_1'X_1\beta_1 = X_1'Y$$

Ratkaistaan (3) β_1 :n suhteen:

$$(4) \hat{\beta}_1 = (X_1'X_1)^{-1}X_1'(Y-Y\hat{\gamma})$$

Sijoitetaan (4) kaavaan (2):

$$(5) Y'X(X'X)^{-1}X'Y\hat{\gamma} + Y'X_1(X_1'X_1)^{-1}X_1'(Y-Y\hat{\gamma}) = Y'X(X'X)^{-1}X'Y$$

eli

$$(6) [Y'X(X'X)^{-1}X'Y - Y'X_1(X_1'X_1)^{-1}X_1'Y]\hat{\gamma} = [Y'X(X'X)^{-1}X'Y - Y'X_1(X_1'X_1)^{-1}X_1']Y$$

Kaava (6) taas on²⁾

1) Goldberger, mt., s. 332 kaava (6.17)

2) vrt. Goldberger, mt., s. 177

$$(7) Y'M_1 X_2 D^{-1} X_2' M_1 Y \hat{\gamma} = Y'M_1 X_2 D^{-1} X_2' M_1 Y$$

eli

$$(8) Y'HY\hat{\gamma} = Y'HY$$

josta saadaan

$$(9) \hat{\gamma} = (Y'HY)^{-1} Y'HY = c$$

Täten myös $\hat{\beta}_1$ on b_1 kuten kaavasta (4) havaitaan.

Luku 3.3.4.

Väite: Estimaattori, joka minimoi suhteen $\frac{L(X_2)}{J(X)}$, on rajoitetun informaation maximum likelihood -estimaattori RIML.

Todistus: Teoksessa Wonnacott - Wonnacott: Econometrics, on osoitettu s. 378, että RIML minimoi suhteen

$$(1) \frac{J(X_1)}{J(X)}$$

Toisaalta

$$(2) J(X_1) = J(X) + L(X_2),$$

joten (1) on

$$(3) J(X_1)/J(X) = [J(X) + L(X_2)]/J(X) = 1 + L(X_2)/J(X)$$

joten estimaattori, joka minimoi suhteen $L(X_2)/J(X)$ minimoi myös suhteen $J(X_1)/J(X)$, eli on RIML.

Luku 3.3.5.

Väite: $\hat{\lambda} - 1 = \lambda$ (kaava 3.33)

Todistus: Teoksessa Wonnacott - Wonnacott, Econometrics, on osoitettu s. 378, että $\hat{\lambda}$ on suhteen $J(X_1)/J(X)$ minimiarvo. Vastaavasti λ on suhteen $L(X_2)/J(X)$ minimiarvo. Edellisessä todistuksessa osoitettiin, että aina on

$$(1) J(X_1)/J(X) = 1 + L(X_2)/J(X)$$

Edellisessä todistuksessa osoitettiin myös, että RIML minimoi molemmat suhteet. Tällöin minimipisteet (c) ovat samoja, ja

$$(2) \hat{\lambda} = 1 + \lambda \text{ eli } \hat{\lambda} - 1 = \lambda$$

Luku 3.4.

Väite: k-luokan estimaattori minimoi lausekkeen $(1-k)J(X_1) + kL(X_2)$.

Todistus:

$$(1) J(X_1) = (y - Yc)'M_1(y - Yc) \text{ ja}$$

$$(2) L(X_2) = (y - Yc)'H(y - Yc)$$

Tällöin

$$(3) \frac{\partial [(1-k)J(X_1) + kL(X_2)]}{\partial c} = 2(1-k)Y'M_1Yc - 2(1-k)Y'M_1Y + 2kY'HYc - 2kY'Hy = 0 \Leftrightarrow$$

$$(1-k)Y'M_1Yc + kY'HYc = (1-k)Y'M_1Y + kY'Hy \Leftrightarrow$$

$$Y'[(1-k)M_1 + kH]Yc = Y'[(1-k)M_1 + kH]Y \Leftrightarrow$$

kaava 3.44 sivulla 31.

Kyseessä on minimi, jos lausekkeen (3) toinen derivaatta on positiivisesti definiitti. Toinen derivaatta on $Y'M_1Y + Y'HY$. Jälkimmäinen termi on jo aiemmin osoitettu positiivisesti definiitiksi. Tällöin koko lauseke on positiivisesti definiitti, jos $Y'M_1Y$ on p.d. Tämä taas pitää paikkansa, kun mikään Y:n lineaarikombinaatio Yc , $c \neq 0$, ei PNS-menetelmällä selity täysin muuttujilla x_1, \dots, x_{K_1} : näin voidaan olettaa olevan.

Luku 5.

Väite: $\hat{\gamma} = (R'R)^{-1}R's$ on γ :n konsistentti estimaattori.

Todistus: Todistusta varten oletetaan, että

(1) $\text{plim } T^{-1}R'R$ on olemassa ja ei-singulaarinen

(2) $\text{plim } T^{-1}X'u = \text{plim } T^{-1}X'v = \text{plim } T^{-1}X'V = 0$

Todistuksen ajatuksena on saattaa $s = Z_2'(y - X_1\tilde{p}_1)$ muotoon, jossa yksi termi on $R\gamma$, osa termeistä päättyy $(\pi_2 - \Pi_2\gamma)$:aan ja loput termit sisältävät jonkin tuloista $X'u$, $X'v$ tai $X'V$ tai vastaavan eksogeenisten muuttujien ja virhetermien ristitulon. Tällöin voidaan päätellä, että $\text{plim } (R'R)^{-1}R's = \gamma$.

Koska $T \rightarrow \infty$, voidaan tarkastella tilannetta $T > K$. Tarkastellaan s :n jälkimmäistä osaa $y - X_1\tilde{p}_1$. Todetaan, että

$$(3) y - X_1\tilde{p}_1 = Y\gamma + X_1\beta_1 + u - X_1\tilde{p}_1$$

Sijoitetaan yhtälöön (3) hajotelma

$$(4) \beta_1 = \Pi_1^*\gamma^* = \pi_1 - \Pi_1\gamma$$

jolloin saadaan

$$(5) y - X_1\tilde{p}_1 = Y\gamma + X_1\pi_1 - X_1\Pi_1\gamma + u - X_1\tilde{p}_1$$

\tilde{p}_1 voidaan esittää muodossa (6): (vrt. Goldberger, s.195)

$$(6) \tilde{p}_1 = p_1 + (X_1'X_1)^{-1}X_1'X_2p_2 = p_1 + Bp_2$$

Yhtälö (5) saadaan nyt muotoon

$$(7) y - X_1\tilde{p}_1 = (Y - X_1\Pi_1)\gamma + X_1(\pi_1 - p_1) - X_1Bp_2$$

Toisaalta tiedetään, että (vrt. Goldberger, s.164 ja 174)

$$(8) \pi_1 - p_1 = (X_1'X_1)^{-1}X_1'(X_2D^{-1}X_2'M_1 - I)v \\ = Fv$$

Samoin voidaan päätellä, että

$$(9) \Pi_1 = P_1 + FV$$

Tällöin saadaan yhtälö (7) muotoon

$$(10) y - X_1 \tilde{p}_1 = (Y - X_1 P_1) \gamma - X_1 F V \gamma + X_1 F v - X_1 B p_2$$

Analogisesti kaavan (6) kanssa on voimassa

$$(11) P_1 = \tilde{P}_1 - B P_2$$

Tällöin voidaan (10) esittää muodossa (12)

$$(12) y - X_1 \tilde{p}_1 = (Y - X_1 \tilde{P}_1) \gamma - X_1 B (p_2 - P_2 \gamma) + X_1 F (v - V \gamma)$$

Toisaalta (vrt. Goldberger, s. 175)

$$(13) p_2 = \pi_2 + D^{-1} X_2' M_1 v = \pi_2 + A v \quad \text{ja}$$

$$(14) P_2 = \Pi_2 + A V$$

Tällöin (12) saa muodon

$$(15) y - X_1 \tilde{p}_1 = (Y - X_1 \tilde{P}_1) \gamma - X_1 B (\pi_2 - \Pi_2 \gamma) + X_1 (F-A) (v - V \gamma)$$

Oikean puolen keskimmäinen termi on identifiointirajoituksen mukaan nolla. Havaitaan, että

$$(16) s = Z_2' (y - X_1 \tilde{p}_1) = Z_2' (Y - X_1 \tilde{P}_1) \gamma + Z_2' X_1 (F-A) (v - V \gamma) \\ = R \gamma + Z_2' X_1 (F-A) (v - V \gamma)$$

jolloin

$$(17) \text{plim } \hat{\gamma} = \text{plim } (T^{-1} R' R)^{-1} T^{-1} R' s \\ = (R' R)^{-1} R' R \gamma + \text{plim } (T^{-1} R' R)^{-1} \text{plim } T^{-1} R' Z_2' X_1 (F-A) (v - V \gamma)$$

Havaitaan, että yhtälön (17) oikean puolen jälkimmäinen termi sisältää eksogeenisten muuttujien ristituloja, sillä F päättyy matriisiin X_1' ja A päättyy myös matriisiin X_1' . Täten yhtälö (2) huomioon ottaen $\text{plim } \hat{\gamma} = (R' R)^{-1} R' R \gamma = \gamma$.

LÄHDELUETTELO

TEOKSET

Goldberger, A.S. : Econometric Theory, John Wiley & Sons,
New York 1964

Theil, H. : Principles of Econometrics, North-Holland,
Amsterdam 1971

Wonnacott, R.J. - Wonnacott, T.H. : Econometrics, John Wiley &
Sons, New York 1970

ARTIKKELIT

Chow, G.C. : A Comparison of Alternative Estimators for
Simultaneous Equations, *Econometrica*, Vol. 32
October 1964

Basmann, R.L. : On Finite Sample Distributions of Generalized
Classical Linear Identifiability Test Statistics,
Journal of the American Statistical Association,
Vol. 55, December 1960

Fisher, F.M. : Generalization of the Rank and Order Conditions
for Identifiability, *Econometrica*, Vol. 27,
July 1959

Dutta, M. : The Iterative Instrumental Variables (IIV) Method
of Estimation and Econometric Models Undersized
and Nonlinear in Variables Only - A Note
Econometric Society European Meeting, Helsinki 1976