

Luennoija: Pentti Saikkonen

Laajuus: 5 op.

Tyyppi: Syventävät opinnot

Luentoajat: I periodi ma 10–12, ti 12–14 B322

Suoritustapa: Kurssikoe ti 1.11. klo 9.00-12.00 D123 ja yleistentit, ensimmäinen 17.11.

Kurssimateriaali: Luentomoniste, jossa mainintoja oheislukemistosta.

Laskuharjoitukset: Ti 10–12, C122 (alkaen 13.9.), Pekka Nieminen

- Lisäpisteitä harjoitustehtävien ratkaisemisesta saa kahdessa ensimmäisessä loppukokeessa 1, 2, 3 tai 4, jos ratkaistujen tehtävien määrä on vastaavasti 20, 40, 60 tai 80 prosenttia.
- Lisäpisteet ainoastaan hyväksytysti suoritettujen tenttien arvosanan korotukseen. Edellyttää läsnäoloa harjoitustilaisuudessa.

Esitietovaatimukset

- Todennäköisyyslaskennan kurssi
- Tilastollisen päättelyn kurssi
- Lineaaristen mallien kurssi
- Edellä mainittujen edellyttämät matematiikan kurssit (yhden ja useamman muuttujan differentiaali- ja integraalilaskenta sekä lineaarialgebra ja matriisilaskenta)

Asema opetuksessa

- Tilastollisen päättelyn jatkokurssi on tilastotieteen syventävien opintojen pakollinen kurssi.
- Kurssilla syvennetään ja laajennetaan aineopintojen tilastollista päättelyn kurssilla esitettyä uskottavuuspäätelyä.
- Keskeinen sisältö muodostuu suurimman uskottavuuden estimaattorin asymptoottisten ominaisuuksien ja uskottavuusteorian testien tarkastelusta vektoriparametrisissa malleissa.

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Jono satunnaismuuttujia (sm) X_1, X_2, \dots **konvergoi stokastisesti kohti sm:aa** Z , merkintään, $X_n \xrightarrow{p} Z$ tai $\text{plim}_{n \rightarrow \infty} X_n = Z$, jos

$$P\{|X_n - Z| > \varepsilon\} \xrightarrow{n \rightarrow \infty} 0 \quad \text{kaikilla } \varepsilon > 0. \quad (*)$$

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Jono satunnaismuuttujia (sm) X_1, X_2, \dots **konvergoi stokastisesti kohti sm:aa** Z , merkintään, $X_n \xrightarrow{p} Z$ tai $\text{plim}_{n \rightarrow \infty} X_n = Z$, jos

$$P\{|X_n - Z| > \varepsilon\} \xrightarrow{n \rightarrow \infty} 0 \quad \text{kaikilla } \varepsilon > 0. \quad (*)$$

- Määritelmässä voi vaihtoehtoisesti olla tapahtuma $\{|X_n - Z| \geq \varepsilon\}$.

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Jono satunnaismuuttujia (sm) X_1, X_2, \dots **konvergoi stokastisesti kohti sm:aa** Z , merkintään, $X_n \xrightarrow{p} Z$ tai $plim_{n \rightarrow \infty} X_n = Z$, jos

$$P\{|X_n - Z| > \varepsilon\} \xrightarrow{n \rightarrow \infty} 0 \quad \text{kaikilla } \varepsilon > 0. \quad (*)$$

- Määritelmässä voi vaihtoehtoisesti olla tapahtuma $\{|X_n - Z| \geq \varepsilon\}$.
- X_1, X_2, \dots ja Z ovat $k \times 1$ satunnaisvektoreita (sv), määritelmä on

$$X_n \xrightarrow{p} Z \quad \Leftrightarrow \quad X_{a,n} \xrightarrow{p} Z_a \quad \text{kaikilla } a = 1, \dots, k,$$

kun esimerkiksi $X_{a,n}$ on X_n :n a . komponentti.

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Jono satunnaismuuttujia (sm) X_1, X_2, \dots **konvergoi stokastisesti kohti sm:aa** Z , merkintään, $X_n \xrightarrow{p} Z$ tai $\text{plim}_{n \rightarrow \infty} X_n = Z$, jos

$$P \{ |X_n - Z| > \varepsilon \} \xrightarrow{n \rightarrow \infty} 0 \quad \text{kaikilla } \varepsilon > 0. \quad (*)$$

- Määritelmässä voi vaihtoehtoisesti olla tapahtuma $\{|X_n - Z| \geq \varepsilon\}$.
- X_1, X_2, \dots ja Z ovat $k \times 1$ satunnaisvektoreita (sv), määritelmä on

$$X_n \xrightarrow{p} Z \Leftrightarrow X_{a,n} \xrightarrow{p} Z_a \quad \text{kaikilla } a = 1, \dots, k,$$

kun esimerkiksi $X_{a,n}$ on X_n :n a . komponentti.

- Vaihtoehtoisesti $(*)$:ssä itseisarvo korvataan vektorin normilla $\|\cdot\|$;
 $x \in \mathbb{R}^k, \|x\| = \sqrt{x_1^2 + \dots + x_k^2}$.

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Jono satunnaismuuttujia (sm) X_1, X_2, \dots **konvergoi stokastisesti kohti sm:aa** Z , merkintään, $X_n \xrightarrow{p} Z$ tai $\text{plim}_{n \rightarrow \infty} X_n = Z$, jos

$$P \{ |X_n - Z| > \varepsilon \} \xrightarrow{n \rightarrow \infty} 0 \quad \text{kaikilla } \varepsilon > 0. \quad (*)$$

- Määritelmässä voi vaihtoehtoisesti olla tapahtuma $\{|X_n - Z| \geq \varepsilon\}$.
- X_1, X_2, \dots ja Z ovat $k \times 1$ satunnaisvektoreita (sv), määritelmä on

$$X_n \xrightarrow{p} Z \Leftrightarrow X_{a,n} \xrightarrow{p} Z_a \quad \text{kaikilla } a = 1, \dots, k,$$

kun esimerkiksi $X_{a,n}$ on X_n :n a . komponentti.

- Vaihtoehtoisesti $(*)$:ssä itseisarvo korvataan vektorin normilla $\|\cdot\|$;
 $x \in \mathbb{R}^k, \|x\| = \sqrt{x_1^2 + \dots + x_k^2}$.
- Satunnaismatriisiin tapauksessa määritelmä voidaan palauttaa satunnaisvektorin määritelmään suorittamalla "vektorointi"

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Seuraavassa tarkoitetaan vakiolla c ei-satunnaista (äärellistä) suuretta. Tilastollisissa sovelluksissa on usein tarpeen tietää milloin pätee implikaatio

$$X_n \xrightarrow{P} c \Rightarrow g(X_n) \xrightarrow{P} g(c).$$

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Seuraavassa tarkoitetaan vakiolla c ei-satunnaista (äärellistä) suuretta. Tilastollisissa sovelluksissa on usein tarpeen tietää milloin pätee implikaatio

$$X_n \xrightarrow{P} c \Rightarrow g(X_n) \xrightarrow{P} g(c).$$

- Liittyy ilmeisesti jotenkin funktion g jatkuvuuteen.

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- Seuraavassa tarkoitetaan vakiolla c ei-satunnaista (äärellistä) suuretta. Tilastollisissa sovelluksissa on usein tarpeen tietää milloin pätee implikaatio

$$X_n \xrightarrow{P} c \Rightarrow g(X_n) \xrightarrow{P} g(c).$$

- Liittyy ilmeisesti jotenkin funktion g jatkuvuuteen.
- **Lause 1.1.** Olkoon X_1, X_2, \dots ja c ($k \times 1$). Jos $X_n \xrightarrow{P} c$ ja $g : \mathbb{R}^k \rightarrow \mathbb{R}^l$ jatkuva pisteessä c , niin $g(X_n) \xrightarrow{P} g(c)$.

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- **Lause 1.1.** Olkoon X_1, X_2, \dots ja c ($k \times 1$). Jos $X_n \xrightarrow{P} c$ ja $g : \mathbb{R}^k \rightarrow \mathbb{R}^l$ jatkuva pisteessä c , niin $g(X_n) \xrightarrow{P} g(c)$.

- **Lause 1.1.** Olkoon X_1, X_2, \dots ja c ($k \times 1$). Jos $X_n \xrightarrow{P} c$ ja $g : \mathbb{R}^k \rightarrow \mathbb{R}^l$ jatkuva pisteessä c , niin $g(X_n) \xrightarrow{P} g(c)$.
- Esimerkkitapauksia: $g(x_1, x_2) = x_1 + x_2$ ja $g(x_1, x_2) = x_1 x_2$ (olettaen summa ja tulo määritellyiksi).

Konvergenssikäsitteitä ja tuloksia

Stokastinen konvergenssi

- **Lause 1.1.** Olkoon X_1, X_2, \dots ja c ($k \times 1$). Jos $X_n \xrightarrow{P} c$ ja $g : \mathbb{R}^k \rightarrow \mathbb{R}^l$ jatkuva pisteessä c , niin $g(X_n) \xrightarrow{P} g(c)$.
- Esimerkkitapauksia: $g(x_1, x_2) = x_1 + x_2$ ja $g(x_1, x_2) = x_1 x_2$ (olettaen summa ja tulo määritellyiksi).
- Lauseen tulos pitää paikkansa myös, kun raja-arvo on satunnainen, mutta todistus ei onnistu kopioimalla edellä esitettyä todistusta aivan suoraan. Jatkossa tätä yleistystä ei kuitenkaan tarvita.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Olkoon F_{X_1}, F_{X_2}, \dots jono sm:ien X_1, X_2, \dots kertymäfunktioita ja F_Z sm:n Z kertymäfunktio (esim. $F_Z(x) = P\{Z \leq x\}$).

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Olkoon F_{X_1}, F_{X_2}, \dots jono sm:ien X_1, X_2, \dots kertymäfunktioita ja F_Z sm:n Z kertymäfunktio (esim. $F_Z(x) = P\{Z \leq x\}$).
- Jonon X_1, X_2, \dots sanotaan **konvergoivan jakaumaltaan kohti sm:aa** Z , merkintään $X_n \xrightarrow{d} Z$, jos

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x) \quad \text{kaikissa } F_Z\text{:n jatkuvuuspeisteissä.}$$

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Olkoon F_{X_1}, F_{X_2}, \dots jono sm:ien X_1, X_2, \dots kertymäfunktioita ja F_Z sm:n Z kertymäfunktio (esim. $F_Z(x) = P\{Z \leq x\}$).
- Jonon X_1, X_2, \dots sanotaan **konvergoivan jakaumaltaan kohti sm:aa** Z , merkintään $X_n \xrightarrow{d} Z$, jos

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x) \quad \text{kaikissa } F_Z\text{:n jatkuvuuspeisteissä.}$$

- Yleistys sv:lle sujuu käyttämällä sv:ien kertymäfunktioita (esim. $F_Z(x) = P\{Z_1 \leq x_1, \dots, Z_k \leq x_k\}$, kun $Z = (Z_1, \dots, Z_k)$).

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi:

$X_n \xrightarrow{d} Z$, jos $\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x)$ kaikissa F_Z :n jatkuvuuspeisteissä

- Tilastotieteessä rajajakauma on useimmiten jatkuva, joten Z :n kf $F_Z(x)$ on jatkuva kaikilla x .

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi:

$X_n \xrightarrow{d} Z$, jos $\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x)$ kaikissa F_Z :n jatkuvuuspisteissä

- Tilastotieteessä rajajakauma on useimmiten jatkuva, joten Z :n kf $F_Z(x)$ on jatkuva kaikilla x .
- Epäjatkuvuuspisteitä voi olla korkeintaan numeroituva määrä.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi:

$X_n \xrightarrow{d} Z$, jos $\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x)$ kaikissa F_Z :n jatkuvuuspisteissä

- Tilastotieteessä rajajakauma on useimmiten jatkuva, joten Z :n kf $F_Z(x)$ on jatkuva kaikilla x .
- Epäjatkuvuuspisteitä voi olla korkeintaan numeroituva määrä.
- Kun F_Z on jatkuva, niin "suurilla" n :n arvoilla ja kaikilla x pätee

$$P\{X_n \leq x\} \approx P\{Z \leq x\}.$$

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi:

$X_n \xrightarrow{d} Z$, jos $\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x)$ kaikissa F_Z :n jatkuvuuspeisteissä

- Tilastotieteessä rajajakauma on useimmiten jatkuva, joten Z :n kf $F_Z(x)$ on jatkuva kaikilla x .
- Epäjatkuvuuspeisteitä voi olla korkeintaan numeroituva määrä.
- Kun F_Z on jatkuva, niin "suurilla" n :n arvoilla ja kaikilla x pätee

$$P\{X_n \leq x\} \approx P\{Z \leq x\}.$$

- Kaikkien sm:aa X_n koskevien tapahtumien todennäköisyyksiä voidaan approksimoida käyttäen sm:n Z jakaumaa.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi:

$X_n \xrightarrow{d} Z$, jos $\lim_{n \rightarrow \infty} F_{X_n}(x) = F_Z(x)$ kaikissa F_Z :n jatkuvuuspisteissä

- Tilastotieteessä rajajakauma on useimmiten jatkuva, joten Z :n kf $F_Z(x)$ on jatkuva kaikilla x .
- Epäjatkuvuuspisteitä voi olla korkeintaan numeroituva määrä.
- Kun F_Z on jatkuva, niin "suurilla" n :n arvoilla ja kaikilla x pätee

$$P\{X_n \leq x\} \approx P\{Z \leq x\}.$$

- Kaikkien sm:aa X_n koskevien tapahtumien todennäköisyyksiä voidaan approksimoida käyttäen sm:n Z jakaumaa.
- Tyypillisessä tilastollisessa sovelluksessa X_n on testisuure tai (muunnettu) estimaattori.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Jakaumakonvergenssin tai heikon konvergenssin määrittelyehto $F_{X_n}(x) \rightarrow F_Z(x)$ on havainnollinen, mutta matemaattisesti hankala.

Konvergensikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Jakaumakonvergenssin tai heikon konvergenssin määrittelyehto $F_{X_n}(x) \rightarrow F_Z(x)$ on havainnollinen, mutta matemaattisesti hankala.
- Sv:n $Z = (Z_1, \dots, Z_k)$ **karakteristinen funktio** (kf)

$$\varphi_Z(t) = E[\exp(it'Z)] = E[\cos(t'Z)] + iE[\sin(t'Z)],$$

jossa $i = \sqrt{-1}$, $t = (t_1, \dots, t_k)$ ja $t'Z = \sum_{j=1}^k t_j Z_j$.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Jakaumakonvergenssin tai heikon konvergenssin määrittelyehto $F_{X_n}(x) \rightarrow F_Z(x)$ on havainnollinen, mutta matemaattisesti hankala.

- Sv:n $Z = (Z_1, \dots, Z_k)$ **karakteristinen funktio** (kf)

$$\varphi_Z(t) = E[\exp(it'Z)] = E[\cos(t'Z)] + iE[\sin(t'Z)],$$

jossa $i = \sqrt{-1}$, $t = (t_1, \dots, t_k)$ ja $t'Z = \sum_{j=1}^k t_j Z_j$.

- kf määrää jakauman yksikäsitteisesti

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

Lause 1.2. Olkoon X_1, X_2, \dots ja Z sv:ta $(k \times 1)$. Seuraavat kolme konvergenssia pätevät yhtäpitävästi.

(i) $X_n \xrightarrow{d} Z$

(ii) $\varphi_{X_n}(t) \xrightarrow{n \rightarrow \infty} \varphi_Z(t)$ jokaisella $t \in \mathbb{R}^k$.

(iii) $E[h(X_n)] \xrightarrow{n \rightarrow \infty} E[h(Z)]$ kaikilla reaaliarvoisilla rajoitetuilla ja jatkuvilla funktioilla $h: \mathbb{R}^k \rightarrow \mathbb{R}$.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Jakaumakonvergenssin ”jatkuvan kuvauksen” lause saadaan helposti ekvivalenssista $X_n \xrightarrow{d} Z \Leftrightarrow E[h(X_n)] \xrightarrow{n \rightarrow \infty} E[h(Z)]$ kaikilla reaaliarvoisilla rajoitetuilla ja jatkuvilla funktioilla h .

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Jakaumakonvergenssin ”jatkuvan kuvauksen” lause saadaan helposti ekvivalenssista $X_n \xrightarrow{d} Z \Leftrightarrow E[h(X_n)] \xrightarrow{n \rightarrow \infty} E[h(Z)]$ kaikilla reaaliarvoisilla rajoitetuilla ja jatkuvilla funktioilla h .
- **Lause 1.3.** Olkoon X_1, X_2, \dots ja $Z (k \times 1)$. Jos $X_n \xrightarrow{d} Z$ ja $g : \mathbb{R}^k \rightarrow \mathbb{R}^l$ on jatkuva, niin $g(X_n) \xrightarrow{d} g(Z)$.

Konvergenssikäsitteitä ja tuloksia

Jakaumakonvergenssi

- Jakaumakonvergenssin ”jatkuvan kuvauksen” lause saadaan helposti ekvivalenssista $X_n \xrightarrow{d} Z \Leftrightarrow E[h(X_n)] \xrightarrow{n \rightarrow \infty} E[h(Z)]$ kaikilla reaaliarvoisilla rajoitetuilla ja jatkuvilla funktioilla h .
- **Lause 1.3.** Olkoon X_1, X_2, \dots ja $Z (k \times 1)$. Jos $X_n \xrightarrow{d} Z$ ja $g : \mathbb{R}^k \rightarrow \mathbb{R}^l$ on jatkuva, niin $g(X_n) \xrightarrow{d} g(Z)$.
- Lievennys: Riittää, että g on jatkuva vain joukossa C_g , jolle pätee $P\{Z \in C_g\} = 1$.

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

- Asymptoottisessa tilastollisessa päättelyssä joudutaan usein käyttämään samanaikaisesti sekä jakaumakonvergenssia että stokastista konvergenssia eli tilanne on $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$.

Tällöin seuraava lause on hyödyllinen.

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

- Asymptoottisessa tilastollisessa päättelyssä joudutaan usein käyttämään samanaikaisesti sekä jakaumakonvergenssia että stokastista konvergenssia eli tilanne on $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$.

Tällöin seuraava lause on hyödyllinen.

- **Lause 1.4.** Oletetaan, että $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} c$ ($l \times 1$), jossa c on vakiovektori. Tällöin $(X_n, Y_n) \xrightarrow{d} (Z, c)$.

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

- Asymptoottisessa tilastollisessa päättelyssä joudutaan usein käyttämään samanaikaisesti sekä jakaumakonvergenssia että stokastista konvergenssia eli tilanne on $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$.

Tällöin seuraava lause on hyödyllinen.

- Lause 1.4.** Oletetaan, että $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} c$ ($l \times 1$), jossa c on vakiovektori. Tällöin $(X_n, Y_n) \xrightarrow{d} (Z, c)$.
- Yhdistettynä jakaumakonvergenssin jatkuvan kuvauksen lauseeseen seuraa tästä

$g(X_n, Y_n) \xrightarrow{d} g(Z, c)$, kun funktio $(z, c) \mapsto g(z, c)$ on jatkuva.

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.1.** $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$ (vakio) reaalisia. Tällöin,

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.1.** $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$ (vakio) reaalisia. Tällöin,
- (i) $X_n + Y_n \xrightarrow{d} Z + c$ $[(z, c) \mapsto z + c \text{ jatkuva}]$

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.1.** $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$ (vakio) reaalisia. Tällöin,
 - (i) $X_n + Y_n \xrightarrow{d} Z + c$ $[(z, c) \mapsto z + c \text{ jatkuva}]$
 - (ii) $X_n Y_n \xrightarrow{d} Zc$ $[(x, c) \mapsto xc \text{ jatkuva}]$

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.1.** $X_n \xrightarrow{d} Z$ ja $Y_n \xrightarrow{p} c$ (vakio) reaalisia. Tällöin,
 - (i) $X_n + Y_n \xrightarrow{d} Z + c$ $[(z, c) \mapsto z + c \text{ jatkuva}]$
 - (ii) $X_n Y_n \xrightarrow{d} Zc$ $[(x, c) \mapsto xc \text{ jatkuva}]$
 - (iii) $X_n / Y_n \xrightarrow{d} Z/c, c \neq 0$ $[(z, c) \mapsto z/c \text{ jatkuva, kun } c \neq 0]$

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.2.** $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} A$ ($l \times k$), A vakiomatriisi.
Tällöin,

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.2.** $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} A$ ($l \times k$), A vakiomatriisi.
Tällöin,
- (i) $Y_n X_n \xrightarrow{d} AZ$

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.2.** $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} A$ ($l \times k$), A vakiomatriisi.
Tällöin,
 - (i) $Y_n X_n \xrightarrow{d} AZ$
 - (ii) $X_n' Y_n X_n \xrightarrow{d} Z' A Z$, kun $k = l$

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.2.** $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} A$ ($l \times k$), A vakiomatriisi.
Tällöin,
 - (i) $Y_n X_n \xrightarrow{d} AZ$
 - (ii) $X_n' Y_n X_n \xrightarrow{d} Z' A Z$, kun $k = l$
 - (iii) $X_n' Y_n^{-1} X_n \xrightarrow{d} Z' A^{-1} Z$, $k = l$ ja A on epäsingulaarinen.

Konvergenssikäsitteitä ja tuloksia

Stokastista konvergenssia ja jakaumakonvergenssia koskevia tuloksia

$$X_n \xrightarrow{d} Z \text{ ja } Y_n \xrightarrow{p} c \implies (X_n, Y_n) \xrightarrow{d} (Z, c)$$

- **Seuraus 1.2.** $X_n \xrightarrow{d} Z$ ($k \times 1$) ja $Y_n \xrightarrow{p} A$ ($l \times k$), A vakiomatriisi.
Tällöin,
 - (i) $Y_n X_n \xrightarrow{d} AZ$
 - (ii) $X_n' Y_n X_n \xrightarrow{d} Z' A Z$, kun $k = l$
 - (iii) $X_n' Y_n^{-1} X_n \xrightarrow{d} Z' A^{-1} Z$, $k = l$ ja A on epäsingulaarinen.
- Perustelu: Kuvaukset $(A, z) \mapsto Az$, $(A, z) \mapsto z'Az$ ja $A \mapsto A^{-1}$ (A epäsing.) jatkuvia.

Konvergensikäsitteitä ja tuloksia

Sovellus deltamenetelmään

- Olkoon $\theta \in \Theta \subseteq \mathbb{R}$ estimoitava parametri, θ_0 sen "todellinen" arvo ja parametrivaruus Θ avoin väli. Tarkastellaan θ_0 :n asympotoottisesti normaalia estimaattoria $\hat{\theta}_n$:

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}(0, \sigma^2(\theta_0)) \quad (\sigma^2(\theta_0) > 0).$$

Konvergenssikäsitteitä ja tuloksia

Sovellus deltamenetelmään

- Olkoon $\theta \in \Theta \subseteq \mathbb{R}$ estimoitava parametri, θ_0 sen "todellinen" arvo ja parametrivaruus Θ avoin väli. Tarkastellaan θ_0 :n asympotoottisesti normaalia estimaattoria $\hat{\theta}_n$:

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N(0, \sigma^2(\theta_0)) \quad (\sigma^2(\theta_0) > 0).$$

- Jos $h : \Theta \rightarrow \mathbb{R}$ on jatkuvasti derivoituva ja $h'(\theta_0) \neq 0$, niin

$$\sqrt{n}(h(\hat{\theta}_n) - h(\theta_0)) \xrightarrow{d} N(0, [h'(\theta_0)]^2 \sigma^2(\theta_0)).$$

Konvergenssikäsitteitä ja tuloksia

Sovellus deltamenetelmään

- Olkoon $\theta \in \Theta \subseteq \mathbb{R}$ estimoitava parametri, θ_0 sen "todellinen" arvo ja parametrivaruus Θ avoin väli. Tarkastellaan θ_0 :n asympotoottisesti normaalia estimaattoria $\hat{\theta}_n$:

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N(0, \sigma^2(\theta_0)) \quad (\sigma^2(\theta_0) > 0).$$

- Jos $h : \Theta \rightarrow \mathbb{R}$ on jatkuvasti derivoituva ja $h'(\theta_0) \neq 0$, niin

$$\sqrt{n}(h(\hat{\theta}_n) - h(\theta_0)) \xrightarrow{d} N(0, [h'(\theta_0)]^2 \sigma^2(\theta_0)).$$

- Perustelu (HT 1.3) nojaa väliarvolauseeseen ja Lauseisiin 1.1, 1.3 ja 1.4 (tai jälkimmäisten seuraukseen).

Konvergenssikäsitteitä ja tuloksia

Sovellus deltamenetelmään

- Olkoon $\theta \in \Theta \subseteq \mathbb{R}$ estimoitava parametri, θ_0 sen "todellinen" arvo ja parametrivaruus Θ avoin väli. Tarkastellaan θ_0 :n asympotoottisesti normaalia estimaattoria $\hat{\theta}_n$:

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N(0, \sigma^2(\theta_0)) \quad (\sigma^2(\theta_0) > 0).$$

- Jos $h : \Theta \rightarrow \mathbb{R}$ on jatkuvasti derivoituva ja $h'(\theta_0) \neq 0$, niin

$$\sqrt{n}(h(\hat{\theta}_n) - h(\theta_0)) \xrightarrow{d} N(0, [h'(\theta_0)]^2 \sigma^2(\theta_0)).$$

- Perustelu (HT 1.3) nojaa väliarvolauseeseen ja Lauseisiin 1.1, 1.3 ja 1.4 (tai jälkimmäisten seuraukseen).
- Tiedoksi lievennys: Funktion h jatkuva derivoituvuus riittää olettaa vain jollain (pienellä) θ_0 :n sisältävällä välillä.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- Tilastollisessa päättelyssä tarkastellaan usein parametrissa riippuvia X_n :iä ja niistä muodostettuja jonoja:

$$X_1(\theta), X_2(\theta), \dots, \theta \in \Theta.$$

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- Tilastollisessa päättelyssä tarkastellaan usein parametrissa riippuvia sm:ia ja niistä muodostettuja jonoja:

$$X_1(\theta), X_2(\theta), \dots, \theta \in \Theta.$$

- Esimerkiksi

$$X_n(\theta) = \frac{1}{n} \sum_{i=1}^n q(Y_i; \theta), \quad \text{jossa } q(Y_i; \theta) = \log f(Y_i; \theta)$$

eli $n^{-1} \times \log$ -uskottavuusfunktio riippumattomien ja samoin jakautuneiden havaintojen Y_1, \dots, Y_n tapauksessa (iid-tapauksessa).

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- Tilastollisessa päättelyssä tarkastellaan usein parametrissa riippuvia sm:ia ja niistä muodostettuja jonoja:

$$X_1(\theta), X_2(\theta), \dots, \theta \in \Theta.$$

- Esimerkiksi

$$X_n(\theta) = \frac{1}{n} \sum_{i=1}^n q(Y_i; \theta), \quad \text{jossa } q(Y_i; \theta) = \log f(Y_i; \theta)$$

eli $n^{-1} \times \log$ -uskottavuusfunktio riippumattomien ja samoin jakautuneiden havaintojen Y_1, \dots, Y_n tapauksessa (iid-tapauksessa).

- Todennäköisyydet lasketaan olettaen "todellinen" parametriarvo θ_0 tai havaintojen jakauma $\prod_{i=1}^n f(Y_i; \theta_0)$

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- Jono reaaliarvoisia satunnaisfunktioita $X_1(\theta), X_2(\theta), \dots, \theta \in \Theta$, **konvergoi stokastisesti ja tasaisesti** kohti ei-satunnaista funktiota $c(\theta)$, jos

$$\sup_{\theta \in \Theta} |X_n(\theta) - c(\theta)| \xrightarrow{P} 0.$$

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- Jono reaaliarvoisia satunnaisfunktioita $X_1(\theta), X_2(\theta), \dots, \theta \in \Theta$, **konvergoi stokastisesti ja tasaisesti** kohti ei-satunnaista funktiota $c(\theta)$, jos

$$\sup_{\theta \in \Theta} |X_n(\theta) - c(\theta)| \xrightarrow{P} 0.$$

- Tällöin $X_n(\theta)$ on "suurilla" n ja "lähes ykkösen" todennäköisyydellä "lähellä" funktiota $c(\theta)$ eikä "läheisyys" riipu siitä mikä parametriarvo on kysymyksessä.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- Jono reaaliarvoisia satunnaisfunktioita $X_1(\theta), X_2(\theta), \dots, \theta \in \Theta$, **konvergoi stokastisesti ja tasaisesti** kohti ei-satunnaista funktiota $c(\theta)$, jos

$$\sup_{\theta \in \Theta} |X_n(\theta) - c(\theta)| \xrightarrow{P} 0.$$

- Tällöin $X_n(\theta)$ on "suurilla" n ja "lähes ykkösen" todennäköisyydellä "lähellä" funktiota $c(\theta)$ eikä "läheisyys" riipu siitä mikä parametriarvo on kysymyksessä.
- Vaatii enemmän kuin **pisteittäinen stokastinen konvergenssi** $X_n(\theta) \xrightarrow{P} c(\theta)$ jokaisella $\theta \in \Theta$ eli

$$|X_n(\theta) - c(\theta)| \xrightarrow{P} 0 \quad \text{jokaisella } \theta \in \Theta.$$

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

Tasaisen stokastisen konvergenssin sovelluksia.

- Suurimman uskottavuuden (SU) estimaattorin (ja muiden saman tyyppisten estimaattoreiden) tarkentuvuuden toteaminen.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

Tasaisen stokastisen konvergenssin sovelluksia.

- Suurimman uskottavuuden (SU) estimaattorin (ja muiden saman tyyppisten estimaattoreiden) tarkentuvuuden toteaminen.
- Olkoon $\hat{\theta}_n$ parametrin θ_0 tarkentuva estimaattori eli $\hat{\theta}_n \xrightarrow{P} \theta_0$ ja $X_n(\theta_0) \xrightarrow{P} c(\theta_0)$ tai $X_n(\theta) \xrightarrow{P} c(\theta)$ jokaisella $\theta \in \Theta$ pätee.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

Tasaisen stokastisen konvergenssin sovelluksia.

- Suurimman uskottavuuden (SU) estimaattorin (ja muiden saman tyyppisten estimaattoreiden) tarkentuvuuden toteaminen.
- Olkoon $\hat{\theta}_n$ parametrin θ_0 tarkentuva estimaattori eli $\hat{\theta}_n \xrightarrow{P} \theta_0$ ja $X_n(\theta_0) \xrightarrow{P} c(\theta_0)$ tai $X_n(\theta) \xrightarrow{P} c(\theta)$ jokaisella $\theta \in \Theta$ pätee.
 - Pätee $X_n(\hat{\theta}_n) \xrightarrow{P} c(\theta_0)$?

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

Tasaisen stokastisen konvergenssin sovelluksia.

- Suurimman uskottavuuden (SU) estimaattorin (ja muiden saman tyyppisten estimaattoreiden) tarkentuvuuden toteaminen.
- Olkoon $\hat{\theta}_n$ parametrin θ_0 tarkentuva estimaattori eli $\hat{\theta}_n \xrightarrow{P} \theta_0$ ja $X_n(\theta_0) \xrightarrow{P} c(\theta_0)$ tai $X_n(\theta) \xrightarrow{P} c(\theta)$ jokaisella $\theta \in \Theta$ pätee.
 - Pätee $X_n(\hat{\theta}_n) \xrightarrow{P} c(\theta_0)$?
 - Pätee, jos stokastinen konvergenssi $X_n(\theta) \xrightarrow{P} c(\theta)$ on tasainen, mutta ei välttämättä muuten.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- **Lause 1.5.** Oletetaan, että

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- **Lause 1.5.** Oletetaan, että
 - $X_n(\theta) \xrightarrow{P} c(\theta)$ tasaisesti joukossa Θ

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- **Lause 1.5.** Oletetaan, että
 - $X_n(\theta) \xrightarrow{P} c(\theta)$ tasaisesti joukossa Θ
 - funktio $c(\theta)$ on jatkuva pisteessä θ_0 ja

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- **Lause 1.5.** Oletetaan, että
 - $X_n(\theta) \xrightarrow{P} c(\theta)$ tasaisesti joukossa Θ
 - funktio $c(\theta)$ on jatkuva pisteessä θ_0 ja
 - $\hat{\theta}_n \xrightarrow{P} \theta_0$.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- **Lause 1.5.** Oletetaan, että
 - $X_n(\theta) \xrightarrow{P} c(\theta)$ tasaisesti joukossa Θ
 - funktio $c(\theta)$ on jatkuva pisteessä θ_0 ja
 - $\hat{\theta}_n \xrightarrow{P} \theta_0$.
- Tällöin, $X_n(\hat{\theta}_n) \xrightarrow{P} c(\theta_0)$.

Konvergenssikäsitteitä ja tuloksia

Tasainen stokastinen konvergenssi

- **Lause 1.5.** Oletetaan, että
 - $X_n(\theta) \xrightarrow{P} c(\theta)$ tasaisesti joukossa Θ
 - funktio $c(\theta)$ on jatkuva pisteessä θ_0 ja
 - $\hat{\theta}_n \xrightarrow{P} \theta_0$.
- Tällöin, $X_n(\hat{\theta}_n) \xrightarrow{P} c(\theta_0)$.
- Sovelletaan myöhemmin, kun $X_n(\theta)$ on $n^{-1} \times$ havaittu informaatiomatriisi ja siten tyyppiä

$$X_n(\theta) = n^{-1} \sum_{i=1}^n q(Y_i; \theta) \quad \text{tai} \quad X_n(\theta) = n^{-1} \sum_{i=1}^n q_i(Y_i; \theta).$$

Tn-laskennan kurssilla on esitetty iid-jonojen suurten lukujen laki.

- Jos X_1, X_2, \dots on reaalinen iid-jono, $E(X_i) = \mu$ ja $\text{Var}(X_i) = \sigma^2 < \infty$, niin

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{p} \mu.$$

Todistus seuraa helposti Tšebyševin (tai Markovin) epäyhtälöstä.

Tn-laskennan kurssilla on esitetty iid-jonojen suurten lukujen laki.

- Jos X_1, X_2, \dots on reaalinen iid-jono, $E(X_i) = \mu$ ja $\text{Var}(X_i) = \sigma^2 < \infty$, niin

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{p} \mu.$$

Todistus seuraa helposti Tšebyševin (tai Markovin) epäyhtälöstä.

- Tilastollisen päättelyn sovelluksissa riippumattomuus ja/tai samoin jakautuneisuus eivät useinkaan päde.

- Riippumattomuutta ei yleensä voida perustella aikasarja-aineistoissa (esim. päivittäinen lämpötila Kaisaniemessä kesäkuussa 2011).

- Riippumattomuutta ei yleensä voida perustella aikasarja-aineistoissa (esim. päivittäinen lämpötila Kaisaniemessä kesäkuussa 2011).
- Samoin lääketieteellisissä kokeissa, joissa havaintoina on mittaustuloksia samoista koehenkilöistä eri ajankohtina. Tällöin eri koehenkilöiden mittaustuloksia voidaan kuitenkin pitää yleensä riippumattomina.

- Riippumattomuutta ei yleensä voida perustella aikasarja-aineistoissa (esim. päivittäinen lämpötila Kaisaniemessä kesäkuussa 2011).
- Samoin lääketieteellisissä kokeissa, joissa havaintoina on mittaustuloksia samoista koehenkilöistä eri ajankohtina. Tällöin eri koehenkilöiden mittaustuloksia voidaan kuitenkin pitää yleensä riippumattomina.
- Regressiomallien tyypisissä malleissa havaintoja ei voida useinkaan pitää samoin jakautuneina (pätee esim. edelliseen tilanteeseen).

- Riippumattomuutta ei yleensä voida perustella aikasarja-aineistoissa (esim. päivittäinen lämpötila Kaisaniemessä kesäkuussa 2011).
- Samoin lääketieteellisissä kokeissa, joissa havaintoina on mittaustuloksia samoista koehenkilöistä eri ajankohtina. Tällöin eri koehenkilöiden mittaustuloksia voidaan kuitenkin pitää yleensä riippumattomina.
- Regressiomallien tyypisissä malleissa havaintoja ei voida useinkaan pitää samoin jakautuneina (pätee esim. edelliseen tilanteeseen).
- Miten SLL toimii tällaisissa tapauksissa?

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- Oletetaan ensin, että jono X_1, X_2, \dots on iiid, mutta $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 < \infty$ vaihtelevat.

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- Oletetaan ensin, että jono X_1, X_2, \dots on iiid, mutta $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 < \infty$ vaihtelevat.
- Tällöin $E(\bar{X}_n) = n^{-1} \sum_{i=1}^n \mu_i$ ja $\text{Var}(\bar{X}_n) = n^{-2} \sum_{i=1}^n \sigma_i^2$ (iiid).

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- Oletetaan ensin, että jono X_1, X_2, \dots on iiid, mutta $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 < \infty$ vaihtelevat.
- Tällöin $E(\bar{X}_n) = n^{-1} \sum_{i=1}^n \mu_i$ ja $\text{Var}(\bar{X}_n) = n^{-2} \sum_{i=1}^n \sigma_i^2$ (iiid).
- Tšebyševin epäyhtälö \Rightarrow

$$P \left\{ \left| \bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \right| > \varepsilon \right\} \leq \frac{1}{\varepsilon^2 n^2} \sum_{i=1}^n \sigma_i^2.$$

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- Oletetaan ensin, että jono X_1, X_2, \dots on , mutta $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 < \infty$ vaihtelevat.
- Tällöin $E(\bar{X}_n) = n^{-1} \sum_{i=1}^n \mu_i$ ja $\text{Var}(\bar{X}_n) = n^{-2} \sum_{i=1}^n \sigma_i^2$ ().
- Tšebyševin epäyhtälö \Rightarrow

$$P \left\{ \left| \bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \right| > \varepsilon \right\} \leq \frac{1}{\varepsilon^2 n^2} \sum_{i=1}^n \sigma_i^2.$$

- Jos (esim.) $\sigma_i^2 \leq C < \infty$ kaikilla i , pätee SLL muodossa

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0.$$

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- Oletetaan nyt, että

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0.$$

- Oletetaan nyt, että

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0.$$

- Jos oletetaan lisäksi konvergenssi $n^{-1} \sum_{i=1}^n \mu_i \rightarrow \mu$, saadaan (ks. Lause 1.1)

$$\bar{X}_n \xrightarrow{p} \mu.$$

- Oletetaan nyt, että

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{P} 0.$$

- Jos oletetaan lisäksi konvergenssi $n^{-1} \sum_{i=1}^n \mu_i \rightarrow \mu$, saadaan (ks. Lause 1.1)

$$\bar{X}_n \xrightarrow{P} \mu.$$

- Tulkitsemalla tässä \bar{X}_n satunnaisvektorin komponentista muodostetuksi keskiarvoksi saadaan perustelu vastaavalle moniulotteiselle yleistykselle.

- Jono s_v :ta X_1, X_2, \dots on m -riippuva, jos kaikilla $k \geq 1$ pätee

$$(X_1, \dots, X_k) \perp\!\!\!\perp (X_{k+l}, X_{k+l+1}, \dots), \quad \text{kun } l > m.$$

- Jono s_v :ta X_1, X_2, \dots on m -riippuva, jos kaikilla $k \geq 1$ pätee

$$(X_1, \dots, X_k) \perp\!\!\!\perp (X_{k+l}, X_{k+l+1}, \dots), \quad \text{kun } l > m.$$

- Kun alaindeksi viittaa havaintoyksikköön, niin havainnot, joiden välinen "etäisyys" on suurempi kuin m ovat riippumattomia.

- Jono sv :ta X_1, X_2, \dots on m -riippuva, jos kaikilla $k \geq 1$ pätee

$$(X_1, \dots, X_k) \perp\!\!\!\perp (X_{k+l}, X_{k+l+1}, \dots), \quad \text{kun } l > m.$$

- Kun alaindeksi viittaa havaintoyksikköön, niin havainnot, joiden välinen "etäisyys" on suurempi kuin m ovat riippumattomia.
- Luonteva oletus, kun havainnot saadaan riippumattomista koehenkilöistä ja kustakin koehenkilöstä on korkeintaan m mittausta.

- Jono sv :ta X_1, X_2, \dots on m -riippuva, jos kaikilla $k \geq 1$ pätee

$$(X_1, \dots, X_k) \perp\!\!\!\perp (X_{k+l}, X_{k+l+1}, \dots), \quad \text{kun } l > m.$$

- Kun alaindeksi viittaa havaintoyksikköön, niin havainnot, joiden välinen "etäisyys" on suurempi kuin m ovat riippumattomia.
- Luonteva oletus, kun havainnot saadaan riippumattomista koehenkilöistä ja kustakin koehenkilöstä on korkeintaan m mittausta.
- Aikasarjatapauksessa riippumattomuus pätee kaikille tapahtumille, joiden välinen ajallinen etäisyys on vähintään m aikayksikköä (ei välttämättä luontevaa mainitussa lämpötilaesimerkissä).

Raja-arvolauseita

Suurten lukijen laki (SLL); m -iippuvuus

- Olkoon sm -jono X_1, X_2, \dots m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .

Raja-arvolauseita

Suurten lukijen laki (SLL); m -riippuvuus

- Olkoon s_m -jono X_1, X_2, \dots m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .
- Kuten riippumattomassa tapauksessa

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0 \quad (\text{vas. odotusarvo} = 0 !)$$

pätee, jos

$$\text{Var}(\bar{X}_n) \xrightarrow{n \rightarrow \infty} 0.$$

Raja-arvolauseita

Suurten lukijen laki (SLL); m -riippuvuus

- Olkoon s_m -jono X_1, X_2, \dots m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .
- Kuten riippumattomassa tapauksessa

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0 \quad (\text{vas. odotusarvo} = 0 !)$$

pätee, jos

$$\text{Var}(\bar{X}_n) \xrightarrow{n \rightarrow \infty} 0.$$

- Tämä todetaan suoralla laskulla.

Raja-arvolauseita

Suurten lukijen laki (SLL); m -riippuvuus

- Oletettiin siis, että sm -jono X_1, X_2, \dots on m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .

Raja-arvolauseita

Suurten lukijen laki (SLL); m -riippuvuus

- Oletettiin siis, että sm -jono X_1, X_2, \dots on m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .
- Todettiin, että tällöin

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0.$$

- Oletettiin siis, että sm-jono X_1, X_2, \dots on m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .

- Todettiin, että tällöin

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0.$$

- Jos oletetaan lisäksi konvergenssi $n^{-1} \sum_{i=1}^n \mu_i \rightarrow \mu$, saadaan

$$\bar{X}_n \xrightarrow{p} \mu.$$

Raja-arvolauseita

Suurten lukijen laki (SLL); m -riippuvuus

- Oletettiin siis, että sm -jono X_1, X_2, \dots on m -riippuva ja $E(X_i) = \mu_i$ ja $\text{Var}(X_i) = \sigma_i^2 \leq C < \infty$ kaikilla i .

- Todettiin, että tällöin

$$\bar{X}_n - \frac{1}{n} \sum_{i=1}^n \mu_i \xrightarrow{p} 0.$$

- Jos oletetaan lisäksi konvergenssi $n^{-1} \sum_{i=1}^n \mu_i \rightarrow \mu$, saadaan

$$\bar{X}_n \xrightarrow{p} \mu.$$

- Tulkitsemalla taas \bar{X}_n satunnaisvektorin komponentista muodostetuksi keskiarvoksi saadaan perustelu vastaavalle moniulotteiselle SLL:lle.

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- SLL voidaan osoittaa myös tapauksissa, joissa $X_i \not\perp\!\!\!\perp X_j$ ei päde olipa $|i - j|$ kuinka suuri tahansa.

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- SLL voidaan osoittaa myös tapauksissa, joissa $X_i \not\perp\!\!\!\perp X_j$ ei päde olipa $|i - j|$ kuinka suuri tahansa.
- Vaatimuksena on kuitenkin, että X_i :n ja X_j :n välinen riippuvuus (tai korrelaatio) "häviää", kun $|i - j| \rightarrow \infty$.

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- SLL voidaan osoittaa myös tapauksissa, joissa $X_i \not\perp\!\!\!\perp X_j$ ei päde olipa $|i - j|$ kuinka suuri tahansa.
- Vaatimuksena on kuitenkin, että X_i :n ja X_j :n välinen riippuvuus (tai korrelaatio) "häviää", kun $|i - j| \rightarrow \infty$.
- Tälle intuitiiviselle luonnehdinnalle on useita matemaattisia muotoilijoita, joita käyttäen SLL:ja on todistettu sallimalla riippuvuuden lisäksi mahdollisesti myös jakaumien heterogeenisuus.

Raja-arvolauseita

Suurten lukijen laki (SLL); ei-iid-tapaus

- SLL voidaan osoittaa myös tapauksissa, joissa $X_i \not\parallel X_j$ ei päde olipa $|i - j|$ kuinka suuri tahansa.
- Vaatimuksena on kuitenkin, että X_i :n ja X_j :n välinen riippuvuus (tai korrelaatio) "häviää", kun $|i - j| \rightarrow \infty$.
- Tälle intuitiiviselle luonnehdinnalle on useita matemaattisia muotoilija, joita käyttäen SLL:ja on todistettu sallimalla riippuvuuden lisäksi mahdollisesti myös jakaumien heterogeisuus.
- SLL ei kuitenkaan päde, jos riippuvuus ja/tai jakaumien heterogeisuus on "liian" voimakasta.

- Tasainen SLL pätee, jos jonolle satunnaisfunktioita $X_1(\theta), X_2(\theta), \dots$, $\theta \in \Theta$, pätee

$$\bar{X}_n(\theta) = \frac{1}{n} \sum_{i=1}^n X_i(\theta) \xrightarrow{p} \mu(\theta) \quad \text{tasaisesti joukossa } \Theta.$$

Tässä $\mu(\theta)$ tulkitaan funktiojonon $n^{-1} \sum_{i=1}^n E[X_i(\theta)]$ raja-arvoksi.

Raja-arvolauseita

Tasainen suurten lukijen laki (SLL)

- Tasainen SLL pätee, jos jonolle satunnaisfunktioita $X_1(\theta), X_2(\theta), \dots$, $\theta \in \Theta$, pätee

$$\bar{X}_n(\theta) = \frac{1}{n} \sum_{i=1}^n X_i(\theta) \xrightarrow{p} \mu(\theta) \quad \text{tasaisesti joukossa } \Theta.$$

Tässä $\mu(\theta)$ tulkitaan funktiojonon $n^{-1} \sum_{i=1}^n E[X_i(\theta)]$ raja-arvoksi.

- Ts.,

$$\sup_{\theta \in \Theta} |\bar{X}_n(\theta) - \mu(\theta)| \xrightarrow{p} 0.$$

Raja-arvolauseita

Tasainen suurten lukijen laki (SLL)

- Vaikka pisteittäinen SLL $\bar{X}_n(\theta) \xrightarrow{P} \mu(\theta)$ (jokaisella $\theta \in \Theta$) voidaan usein todeta kohtuullisen helposti, on tasaisten SSL:ien todistaminen tai edes riittävien ehtojen esittäminen matemaattisesti paljon hankalampaa.

Raja-arvolauseita

Tasainen suurten lukijen laki (SLL)

- Vaikka pisteittäinen SLL $\bar{X}_n(\theta) \xrightarrow{P} \mu(\theta)$ (jokaisella $\theta \in \Theta$) voidaan usein todeta kohtuullisen helposti, on tasaisten SSL:ien todistaminen tai edes riittävien ehtojen esittäminen matemaattisesti paljon hankalampaa.
- iid-tapauksessa ja kun $X_i(\theta) = q(Y_i; \theta)$ riittää, että

Raja-arvolauseita

Tasainen suurten lukijen laki (SLL)

- Vaikka pisteittäinen SLL $\bar{X}_n(\theta) \xrightarrow{P} \mu(\theta)$ (jokaisella $\theta \in \Theta$) voidaan usein todeta kohtuullisen helposti, on tasaisten SSL:ien todistaminen tai edes riittävien ehtojen esittäminen matemaattisesti paljon hankalampaa.
- iid-tapauksessa ja kun $X_i(\theta) = q(Y_i; \theta)$ riittää, että
 - (i) funktio $\theta \mapsto q(y; \theta)$ on jatkuva kaikilla Y_i :n mahdollisilla arvoilla y ,

Raja-arvolauseita

Tasainen suurten lukijen laki (SLL)

- Vaikka pisteittäinen SLL $\bar{X}_n(\theta) \xrightarrow{P} \mu(\theta)$ (jokaisella $\theta \in \Theta$) voidaan usein todeta kohtuullisen helposti, on tasaisten SSL:ien todistaminen tai edes riittävien ehtojen esittäminen matemaattisesti paljon hankalampaa.
- iid-tapauksessa ja kun $X_i(\theta) = q(Y_i; \theta)$ riittää, että
 - (i) funktio $\theta \mapsto q(y; \theta)$ on jatkuva kaikilla Y_i :n mahdollisilla arvoilla y ,
 - (ii) joukko Θ on kompakti (eli suljettu ja rajoitettu) ja

Raja-arvolauseita

Tasainen suurten lukijen laki (SLL)

- Vaikka pisteittäinen SLL $\bar{X}_n(\theta) \xrightarrow{P} \mu(\theta)$ (jokaisella $\theta \in \Theta$) voidaan usein todeta kohtuullisen helposti, on tasaisten SSL:ien todistaminen tai edes riittävien ehtojen esittäminen matemaattisesti paljon hankalampaa.
- iid-tapauksessa ja kun $X_i(\theta) = q(Y_i; \theta)$ riittää, että
 - (i) funktio $\theta \mapsto q(y; \theta)$ on jatkuva kaikilla Y_i :n mahdollisilla arvoilla y ,
 - (ii) joukko Θ on kompakti (eli suljettu ja rajoitettu) ja
 - (iii) $E(\sup_{\theta \in \Theta} |q(Y_1; \theta)|) < \infty$.

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); reaalin iid-tapaus

Tn-laskennan kurssilla on esitetty reaalisten iid-jonojen KRL.

- Jos X_1, X_2, \dots on reaalinen iid-jono, $E(X_i) = \mu$ ja $\text{Var}(X_i) = \sigma^2 < \infty$, niin

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{d} N(0, \sigma^2)$$

tai vaihtoehtoisesti esitettynä (ks. Lause 1.3)

$$\sqrt{n}(\bar{X}_n - \mu) / \sigma \xrightarrow{d} N(0, 1).$$

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); reaalin iid-tapaus

T_n-laskennan kurssilla on esitetty reaalisten iid-jonojen KRL.

- Jos X_1, X_2, \dots on reaalinen iid-jono, $E(X_i) = \mu$ ja $\text{Var}(X_i) = \sigma^2 < \infty$, niin

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{d} N(0, \sigma^2)$$

tai vaihtoehtoisesti esitettynä (ks. Lause 1.3)

$$\sqrt{n}(\bar{X}_n - \mu) / \sigma \xrightarrow{d} N(0, 1).$$

- Käytännön merkitys: Otoskeskiarvon \bar{X}_n (tuntematonta) jakaumaa voidaan "suurilla" n :n arvoilla approksimoida $N(\mu, \sigma^2/n)$ -jakaumalla tai "merkinnällisesti"

$$\bar{X}_n \underset{as}{\sim} N(\mu, \sigma^2/n).$$

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); vektoriarvoinen iid-tapaus

- Jos X_1, X_2, \dots on iid-jono sv:ta ($k \times 1$), $E(X_i) = \mu$ ($k \times 1$) ja $\text{Cov}(X_i) = \Sigma$ ($k \times k$) (äärellinen ja nollasta poikkeava), niin

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{d} N(0, \Sigma).$$

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); vektoriarvoinen iid-tapaus

- Jos X_1, X_2, \dots on iid-jono sv:ta ($k \times 1$), $E(X_i) = \mu$ ($k \times 1$) ja $\text{Cov}(X_i) = \Sigma$ ($k \times k$) (äärellinen ja nollostapoikkeava), niin

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{d} N(0, \Sigma).$$

- Myöhemmin Σ on (ainakin yleensä) epäsingulaarinen. Joissakin sovelluksissa voidaan kuitenkin päätyä singulaariseen raja-jakaumaan.

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); ei-iid-tapaus

- KRL:sta on olemassa lukuisia versioita, joissa sallitaan jakaumien heterogeenisuus ja muuttujien riippuvuus kuten esim. m -riippuvuus.

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); ei-iid-tapaus

- KRL:sta on olemassa lukuisia versioita, joissa sallitaan jakaumien heterogeenisuus ja muuttujien riippuvuus kuten esim. m -riippuvuus.
- Tällaiset KRL:t esitetään (reaaliarvoisessa tapauksessa) usein muodossa

$$(\bar{X}_n - \mu_n) / \sigma_n \xrightarrow{d} N(0, 1),$$

jossa $\mu_n = E(\bar{X}_n)$ ja $\sigma_n^2 = \text{Var}(\bar{X}_n)$ eli "merkinnällisesti"

$$\bar{X}_n \underset{as}{\sim} N(\mu_n, \sigma_n^2).$$

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); ei-iid-tapaus

- KRL:sta on olemassa lukuisia versioita, joissa sallitaan jakaumien heterogeenisuus ja muuttujien riippuvuus kuten esim. m -riippuvuus.
- Tällaiset KRL:t esitetään (reaaliarvoisessa tapauksessa) usein muodossa

$$(\bar{X}_n - \mu_n) / \sigma_n \xrightarrow{d} N(0, 1),$$

jossa $\mu_n = E(\bar{X}_n)$ ja $\sigma_n^2 = \text{Var}(\bar{X}_n)$ eli "merkinnällisesti"

$$\bar{X}_n \underset{as}{\sim} N(\mu_n, \sigma_n^2).$$

- KRL ei päde, jos "poikkeavuus iid-tapauksesta on liiallista".

Raja-arvolauseita

Keskeinen raja-arvolause (KRL); ei-iid-tapaus

- KRL:sta on olemassa lukuisia versioita, joissa sallitaan jakaumien heterogeenisuus ja muuttujien riippuvuus kuten esim. m -riippuvuus.
- Tällaiset KRL:t esitetään (reaaliarvoisessa tapauksessa) usein muodossa

$$(\bar{X}_n - \mu_n) / \sigma_n \xrightarrow{d} N(0, 1),$$

jossa $\mu_n = E(\bar{X}_n)$ ja $\sigma_n^2 = \text{Var}(\bar{X}_n)$ eli "merkinnällisesti"

$$\bar{X}_n \underset{as}{\sim} N(\mu_n, \sigma_n^2).$$

- KRL ei päde, jos "poikkeavuus iid-tapauksesta on liiallista".
- Seuraavassa esitettävä ns. **martingaalien KRL** ja sen eri versiot ovat käyttökelpoisia (erityisesti uskottavuusfunktioon perustuvassa) tilastollisessa päätelyssä.

Raja-arvolauseita

Martingaalien KRL; ehdollista odotusarvoa koskevia tuloksia

- Jos sv:lla Y ja X on jatkuva yhteisjakauma ja $E(|Y|) < \infty$, määritellään Y :n ehdollinen odotusarvo ehdolla $X = x$ yhtälöllä

$$E(Y | X = x) = \int_{-\infty}^{\infty} y \frac{f_{Y,X}(y, x)}{f_X(x)} dy = \int_{-\infty}^{\infty} y f_{Y|X}(y; x) dy.$$

Raja-arvolauseita

Martingaalien KRL; ehdollista odotusarvoa koskevia tuloksia

- Jos sv:lla Y ja X on jatkuva yhteisjakauma ja $E(|Y|) < \infty$, määritellään Y :n ehdollinen odotusarvo ehdolla $X = x$ yhtälöllä

$$E(Y | X = x) = \int_{-\infty}^{\infty} y \frac{f_{Y,X}(y, x)}{f_X(x)} dy = \int_{-\infty}^{\infty} y f_{Y|X}(y; x) dy.$$

- $f_{Y,X}(y, x)$ on (Y, X) :n yhteistiheysfunktio

- Jos sv:lla Y ja X on jatkuva yhteisjakauma ja $E(|Y|) < \infty$, määritellään Y :n ehdollinen odotusarvo ehdolla $X = x$ yhtälöllä

$$E(Y | X = x) = \int_{-\infty}^{\infty} y \frac{f_{Y,X}(y, x)}{f_X(x)} dy = \int_{-\infty}^{\infty} y f_{Y|X}(y; x) dy.$$

- $f_{Y,X}(y, x)$ on (Y, X) :n yhteistiheysfunktio
- $f_X(x) = \int_{-\infty}^{\infty} f_{Y,X}(y, x) dy$ on X :n reunajakauman tf ja

Raja-arvolauseita

Martingaalien KRL; ehdollista odotusarvoa koskevia tuloksia

- Jos sv:lla Y ja X on jatkuva yhteisjakauma ja $E(|Y|) < \infty$, määritellään Y :n ehdollinen odotusarvo ehdolla $X = x$ yhtälöllä

$$E(Y | X = x) = \int_{-\infty}^{\infty} y \frac{f_{Y,X}(y, x)}{f_X(x)} dy = \int_{-\infty}^{\infty} y f_{Y|X}(y; x) dy.$$

- $f_{Y,X}(y, x)$ on (Y, X) :n yhteistiheysfunktio
- $f_X(x) = \int_{-\infty}^{\infty} f_{Y,X}(y, x) dy$ on X :n reunajakauman tf ja
- $f_{Y|X}(y|x) = f_{Y,X}(y, x) / f_X(x)$ on Y :n ehdollinen tiheysfunktio ehdolla $X = x$.

- Jos sv:lla Y ja X on jatkuva yhteisjakauma ja $E(|Y|) < \infty$, määritellään Y :n ehdollinen odotusarvo ehdolla $X = x$ yhtälöllä

$$E(Y | X = x) = \int_{-\infty}^{\infty} y \frac{f_{Y,X}(y, x)}{f_X(x)} dy = \int_{-\infty}^{\infty} y f_{Y|X}(y; x) dy.$$

- $f_{Y,X}(y, x)$ on (Y, X) :n yhteistiheysfunktio
 - $f_X(x) = \int_{-\infty}^{\infty} f_{Y,X}(y, x) dy$ on X :n reunajakauman tf ja
 - $f_{Y|X}(y|x) = f_{Y,X}(y, x) / f_X(x)$ on Y :n ehdollinen tiheysfunktio ehdolla $X = x$.
- Kun x vaihtelee, määrittelee x :n funktio $E(Y | X = x)$ sv:n, jonka luonteva merkintä on $E(Y | X)$. Tätä merkintää käytetään seuraavassa.

Ehdollisella odotusarvolla on tunnetusti mm. seuraavat ominaisuudet.

- **EO1** $E(aY_1 + bY_2 | X) = aE(Y_1 | X) + bE(Y_2 | X)$, kun a ja b ovat vakioita (lineaarisuus).

Ehdollisella odotusarvolla on tunnetusti mm. seuraavat ominaisuudet.

- **EO1** $E(aY_1 + bY_2 | X) = aE(Y_1 | X) + bE(Y_2 | X)$, kun a ja b ovat vakioita (lineaarisuus).
- **EO2** $E(Y | X) = E(Y)$, kun $Y \perp\!\!\!\perp X$.

Ehdollisella odotusarvolla on tunnetusti mm. seuraavat ominaisuudet.

- **EO1** $E(aY_1 + bY_2 | X) = aE(Y_1 | X) + bE(Y_2 | X)$, kun a ja b ovat vakioita (lineaarisuus).
- **EO2** $E(Y | X) = E(Y)$, kun $Y \perp\!\!\!\perp X$.
- **EO3** $E(Y) = E[E(Y | X)]$ (ns. iteroidun odotusarvon laki)

Ehdollisella odotusarvolla on tunnetusti mm. seuraavat ominaisuudet.

- **EO1** $E(aY_1 + bY_2 | X) = aE(Y_1 | X) + bE(Y_2 | X)$, kun a ja b ovat vakioita (lineaarisuus).
- **EO2** $E(Y | X) = E(Y)$, kun $Y \perp\!\!\!\perp X$.
- **EO3** $E(Y) = E[E(Y | X)]$ (ns. iteroidun odotusarvon laki)
- **EO4** $E(g(X) Y | X) = g(X) E(Y | X)$ mille tahansa funktiolle g (jolla vasen puoli on hyvin määritelty).

- **Määritelmä 2.1.** Olkoon Z_1, Z_2, \dots jono sm:ia ja $\mathcal{F}_i = (Z_1, \dots, Z_i)$. Sm-jonoa M_1, M_2, \dots sanotaan **martingaaliksi informaatiojoukon \mathcal{F}_i suhteen**, jos

- **Määritelmä 2.1.** Olkoon Z_1, Z_2, \dots jono sm:ia ja $\mathcal{F}_i = (Z_1, \dots, Z_i)$. Sm-jonoa M_1, M_2, \dots sanotaan **martingaaliksi informaatiojoukon \mathcal{F}_i suhteen**, jos
- (i) $M_i = g_i(\mathcal{F}_i)$ jollain funktiolla g_i ja kaikilla $i = 1, 2, \dots$

- **Määritelmä 2.1.** Olkoon Z_1, Z_2, \dots jono sm:ia ja $\mathcal{F}_i = (Z_1, \dots, Z_i)$. Sm-jonoa M_1, M_2, \dots sanotaan **martingaaliksi informaatiojoukon \mathcal{F}_i suhteen**, jos
 - (i) $M_i = g_i(\mathcal{F}_i)$ jollain funktiolla g_i ja kaikilla $i = 1, 2, \dots$
 - (ii) $E(|M_i|) < \infty$ kaikilla $i = 1, 2, \dots$

- **Määritelmä 2.1.** Olkoon Z_1, Z_2, \dots jono sm:ia ja $\mathcal{F}_i = (Z_1, \dots, Z_i)$. Sm-jonoa M_1, M_2, \dots sanotaan **martingaaliksi informaatiojoukon \mathcal{F}_i suhteen**, jos
 - (i) $M_i = g_i(\mathcal{F}_i)$ jollain funktiolla g_i ja kaikilla $i = 1, 2, \dots$
 - (ii) $E(|M_i|) < \infty$ kaikilla $i = 1, 2, \dots$
 - (iii) $E(M_i | \mathcal{F}_{i-1}) = M_{i-1}$ kaikilla $i = 2, 3, \dots$

- **Määritelmä 2.1.** Olkoon Z_1, Z_2, \dots jono sm:ia ja $\mathcal{F}_i = (Z_1, \dots, Z_i)$. Sm-jonoa M_1, M_2, \dots sanotaan **martingaaliksi informaatiojoukon \mathcal{F}_i suhteen**, jos
 - (i) $M_i = g_i(\mathcal{F}_i)$ jollain funktiolla g_i ja kaikilla $i = 1, 2, \dots$
 - (ii) $E(|M_i|) < \infty$ kaikilla $i = 1, 2, \dots$
 - (iii) $E(M_i | \mathcal{F}_{i-1}) = M_{i-1}$ kaikilla $i = 2, 3, \dots$
- Yleistys tapaukseen, jossa Z_i ja M_i ovat vektoreita on samanlainen, kun kohdassa (ii) itseisarvo korvataan normilla $\|M_i\|$ (tai odotusarvon äärellisyys vaaditaan kaikilta sv:n M_i komponenteilta).

Martingaalin asemesta lähtökohtana on usein martingaalidifferenssi.

S_n -jonoa X_1, X_2, \dots sanotaan **martingaalidifferenssiksi** informaatiojoukon \mathcal{F}_i suhteen, jos

- **(i)** $X_i = h_i(\mathcal{F}_i)$ jollain funktiolla h_i ja kaikilla $i = 1, 2, \dots$

Martingaalin asemesta lähtökohtana on usein martingaalidifferenssi.

S_n -jonoa X_1, X_2, \dots sanotaan **martingaalidifferenssiksi** informaatiojoukon \mathcal{F}_i suhteen, jos

- (i) $X_i = h_i(\mathcal{F}_i)$ jollain funktiolla h_i ja kaikilla $i = 1, 2, \dots$
- (ii) $E(|X_i|) < \infty$ kaikilla $i = 1, 2, \dots$

Martingaalin asemesta lähtökohtana on usein martingaalidifferenssi.

S_n -jonoa X_1, X_2, \dots sanotaan **martingaalidifferenssiksi informaatiojoukon \mathcal{F}_i suhteen**, jos

- **(i)** $X_i = h_i(\mathcal{F}_i)$ jollain funktiolla h_i ja kaikilla $i = 1, 2, \dots$
- **(ii)** $E(|X_i|) < \infty$ kaikilla $i = 1, 2, \dots$
- **(iii)** $E(X_i | \mathcal{F}_{i-1}) = 0$ kaikilla $i = 2, 3, \dots$

Martingaalin asemesta lähtökohtana on usein martingaalidifferenssi.

S_n -jonoa X_1, X_2, \dots sanotaan **martingaalidifferenssiksi informaatiojoukon \mathcal{F}_i suhteen**, jos

- (i) $X_i = h_i(\mathcal{F}_i)$ jollain funktiolla h_i ja kaikilla $i = 1, 2, \dots$
- (ii) $E(|X_i|) < \infty$ kaikilla $i = 1, 2, \dots$
- (iii) $E(X_i | \mathcal{F}_{i-1}) = 0$ kaikilla $i = 2, 3, \dots$
- Tällöin

$$M_i = X_1 + \dots + X_i = M_{i-1} + X_i \quad (M_0 = 0)$$

on martingaali ja, jos $E(X_1) = 0$, niin $E(X_i) = 0$ kaikilla $i \geq 1$.

Martingaalin asemesta lähtökohtana on usein martingaalidifferenssi.

S_n -jonoa X_1, X_2, \dots sanotaan **martingaalidifferenssiksi informaatiojoukon \mathcal{F}_i suhteen**, jos

- (i) $X_i = h_i(\mathcal{F}_i)$ jollain funktiolla h_i ja kaikilla $i = 1, 2, \dots$
- (ii) $E(|X_i|) < \infty$ kaikilla $i = 1, 2, \dots$
- (iii) $E(X_i | \mathcal{F}_{i-1}) = 0$ kaikilla $i = 2, 3, \dots$
- Tällöin

$$M_i = X_1 + \dots + X_i = M_{i-1} + X_i \quad (M_0 = 0)$$

on martingaali ja, jos $E(X_1) = 0$, niin $E(X_i) = 0$ kaikilla $i \geq 1$.

- MD-jonon korreloimattomuudesta seuraa, että reaalissa tapauksessa $\text{Var}(M_n) = \sum_{i=1}^n \text{Var}(X_i)$.

- **Esimerkki 1.1. (i)** Reaalinen iid-jono $\{X_i\}_{i=1}^{\infty}$ on MD, kun $E(X_1) = 0$ ja $\mathcal{F}_i = (X_1, \dots, X_i)$.

- **Esimerkki 1.1. (i)** Reaalinen iid-jono $\{X_i\}_{i=1}^{\infty}$ on MD, kun $E(X_1) = 0$ ja $\mathcal{F}_i = (X_1, \dots, X_i)$.
- **(ii)** $\{X_i\}_{i=1}^{\infty}$ ja $\{Z_i\}_{i=1}^{\infty}$ || ja $\{X_i\}_{i=1}^{\infty}$ kuten kohdassa (i).

- **Esimerkki 1.1. (i)** Reaalinen iid-jono $\{X_i\}_{i=1}^{\infty}$ on MD, kun $E(X_1) = 0$ ja $\mathcal{F}_i = (X_1, \dots, X_i)$.
- **(ii)** $\{X_i\}_{i=1}^{\infty}$ ja $\{Z_i\}_{i=1}^{\infty}$ || ja $\{X_i\}_{i=1}^{\infty}$ kuten kohdassa (i).
 - Tällöin $\{Z_i X_i\}_{i=1}^{\infty}$ on MD, kun $E(|Z_i|) < \infty$ kaikilla $i \geq 1$ ja $\mathcal{F}_i = (X_1, \dots, X_i, Z_1, \dots, Z_{i+1})$.

- **Esimerkki 1.1. (i)** Reaalinen iid-jono $\{X_i\}_{i=1}^{\infty}$ on MD, kun $E(X_1) = 0$ ja $\mathcal{F}_i = (X_1, \dots, X_i)$.
- **(ii)** $\{X_i\}_{i=1}^{\infty}$ ja $\{Z_i\}_{i=1}^{\infty}$ || ja $\{X_i\}_{i=1}^{\infty}$ kuten kohdassa (i).
 - Tällöin $\{Z_i X_i\}_{i=1}^{\infty}$ on MD, kun $E(|Z_i|) < \infty$ kaikilla $i \geq 1$ ja $\mathcal{F}_i = (X_1, \dots, X_i, Z_1, \dots, Z_{i+1})$.
- **(iii)** $\{X_i\}_{i=1}^{\infty}$ kuten kohdassa (i), $Z_1 = c$ (vakio) ja $Z_i = g_i(X_1, \dots, X_{i-1})$, $i \geq 2$.

- **Esimerkki 1.1. (i)** Reaalinen iid-jono $\{X_i\}_{i=1}^{\infty}$ on MD, kun $E(X_1) = 0$ ja $\mathcal{F}_i = (X_1, \dots, X_i)$.
- **(ii)** $\{X_i\}_{i=1}^{\infty}$ ja $\{Z_i\}_{i=1}^{\infty}$ || ja $\{X_i\}_{i=1}^{\infty}$ kuten kohdassa (i).
 - Tällöin $\{Z_i X_i\}_{i=1}^{\infty}$ on MD, kun $E(|Z_i|) < \infty$ kaikilla $i \geq 1$ ja $\mathcal{F}_i = (X_1, \dots, X_i, Z_1, \dots, Z_{i+1})$.
- **(iii)** $\{X_i\}_{i=1}^{\infty}$ kuten kohdassa (i), $Z_1 = c$ (vakio) ja $Z_i = g_i(X_1, \dots, X_{i-1})$, $i \geq 2$.
 - Tällöin $\{Z_i X_i\}_{i=1}^{\infty}$ on MD, kun $E(|Z_i|) < \infty$ kaikilla $i \geq 2$ ja $\mathcal{F}_i = (X_1, \dots, X_i)$.

Raja-arvolauseita

Yksi useista martingaalien KRL:sta

- **Lause 1.6.** Olkoon X_1, X_2, \dots ($k \times 1$) MD-jono jonkun informaatiojoukon suhteen. Oletetaan

Raja-arvolauseita

Yksi useista martingaalien KRL:sta

- **Lause 1.6.** Olkoon X_1, X_2, \dots ($k \times 1$) MD-jono jonkun informaatiojoukon suhteen. Oletetaan
- (i) $E(|X_{a,i}|^{2+\delta}) \leq C < \infty$ jollain $\delta > 0$, $\forall i \geq 1$ ja $a = 1, \dots, k$

Raja-arvolauseita

Yksi useista martingaalien KRL:sta

- **Lause 1.6.** Olkoon X_1, X_2, \dots ($k \times 1$) MD-jono jonkun informaatiojoukon suhteen. Oletetaan
- (i) $E(|X_{a,i}|^{2+\delta}) \leq C < \infty$ jollain $\delta > 0$, $\forall i \geq 1$ ja $a = 1, \dots, k$
- (ii) $n^{-1} \sum_{i=1}^n X_i X_i' \xrightarrow{p} \Sigma$ (nollasta poikkeava ja äärellinen),

Raja-arvolauseita

Yksi useista martingaalien KRL:sta

- **Lause 1.6.** Olkoon X_1, X_2, \dots ($k \times 1$) MD-jono jonkun informaatiojoukon suhteen. Oletetaan
- (i) $E(|X_{a,i}|^{2+\delta}) \leq C < \infty$ jollain $\delta > 0$, $\forall i \geq 1$ ja $a = 1, \dots, k$
- (ii) $n^{-1} \sum_{i=1}^n X_i X_i' \xrightarrow{p} \Sigma$ (nollasta poikkeava ja äärellinen),
- Tällöin,

Raja-arvolauseita

Yksi useista martingaalien KRL:sta

- **Lause 1.6.** Olkoon X_1, X_2, \dots ($k \times 1$) MD-jono jonkun informaatiojoukon suhteen. Oletetaan
- (i) $E(|X_{a,i}|^{2+\delta}) \leq C < \infty$ jollain $\delta > 0$, $\forall i \geq 1$ ja $a = 1, \dots, k$
- (ii) $n^{-1} \sum_{i=1}^n X_i X_i' \xrightarrow{p} \Sigma$ (nollasta poikkeava ja äärellinen),
- Tällöin,
 -

$$\text{Cov} \left(n^{-1/2} \sum_{i=1}^n X_i \right) \xrightarrow{n \rightarrow \infty} \Sigma \quad \Leftrightarrow \quad n^{-1} \sum_{i=1}^n E(X_i X_i') \xrightarrow{n \rightarrow \infty} \Sigma$$

Raja-arvolauseita

Yksi useista martingaalien KRL:sta

- **Lause 1.6.** Olkoon X_1, X_2, \dots ($k \times 1$) MD-jono jonkun informaatiojoukon suhteen. Oletetaan
- (i) $E(|X_{a,i}|^{2+\delta}) \leq C < \infty$ jollain $\delta > 0$, $\forall i \geq 1$ ja $a = 1, \dots, k$
- (ii) $n^{-1} \sum_{i=1}^n X_i X_i' \xrightarrow{p} \Sigma$ (nollasta poikkeava ja äärellinen),
- Tällöin,

-

$$\text{Cov} \left(n^{-1/2} \sum_{i=1}^n X_i \right) \xrightarrow{n \rightarrow \infty} \Sigma \quad \Leftrightarrow \quad n^{-1} \sum_{i=1}^n E(X_i X_i') \xrightarrow{n \rightarrow \infty} \Sigma$$

- ja

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n X_i \xrightarrow{d} N(0, \Sigma).$$

- Tilastollisen tutkimuksen lähtökohtana aineisto $\mathbf{y} = (y_1, \dots, y_n)$, jossa y_i on havaintoyksikköön i liittyvä havainto.

- Tilastollisen tutkimuksen lähtökohtana aineisto $\mathbf{y} = (y_1, \dots, y_n)$, jossa y_i on havaintoyksikköön i liittyvä havainto.
- Havainnot voivat olla joko reaaliarvoisia tai vektoriarvoisia ja ne tulkitaan sm:ien tai sv:ien Y_1, \dots, Y_n havaituiksi arvoiksi.

- Tilastollisen tutkimuksen lähtökohtana aineisto $\mathbf{y} = (y_1, \dots, y_n)$, jossa y_i on havaintoyksikköön i liittyvä havainto.
- Havainnot voivat olla joko reaaliarvoisia tai vektoriarvoisia ja ne tulkitaan sm:ien tai sv:ien Y_1, \dots, Y_n havaituiksi arvoiksi.
- Esimerkki vektoritapauksesta on $Y_1, \dots, Y_n \sim N_k(\mu, \Sigma) \underline{\underline{\quad}}$.

- Tilastollisen tutkimuksen lähtökohtana aineisto $\mathbf{y} = (y_1, \dots, y_n)$, jossa y_i on havaintoyksikköön i liittyvä havainto.
- Havainnot voivat olla joko reaaliarvoisia tai vektoriarvoisia ja ne tulkitaan sm:ien tai sv:ien Y_1, \dots, Y_n havaituiksi arvoiksi.
- Esimerkki vektoritapauksesta on $Y_1, \dots, Y_n \sim N_k(\mu, \Sigma) \parallel$.
- Tilastollinen malli on sv:n $\mathbf{Y} = (Y_1, \dots, Y_n)$ yhteistiheysfunktio (ytf) tai yhteispistetodennäköisyysfunktio (yptf), joka rajataan käytettävissä olevan taustatiedon perusteella.

- Tarkasteltavassa parametrisessa tilastollisessa päätelyssä oletetaan, että ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$ riippuu tuntemattomasta parametrista $\theta = (\theta_1, \dots, \theta_d) \in \Theta \subseteq \mathbb{R}^d$.

- Tarkasteltavassa parametrisessa tilastollisessa päätelyssä oletetaan, että ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$ riippuu tuntemattomasta parametrusta $\theta = (\theta_1, \dots, \theta_d) \in \Theta \subseteq \mathbb{R}^d$.
- Mahdollisten parametriarvojen joukon Θ määrittely on osa mallin spesifointia.

- Tarkasteltavassa parametrisessa tilastollisessa päätelyssä oletetaan, että ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$ riippuu tuntemattomasta parametrasta $\theta = (\theta_1, \dots, \theta_d) \in \Theta \subseteq \mathbb{R}^d$.
- Mahdollisten parametriarvojen joukon Θ määrittely on osa mallin spesifiointia.
- Tavoitteena on tehdä päätelmiä tuntemattomasta parametrasta θ aineiston \mathbf{y} perusteella. Joissakin yhteyksissä on hyödyllistä osoittaa havaintomäärä vektoreissa \mathbf{y} ja \mathbf{Y} . Tällöin merkitään \mathbf{y}_n ja \mathbf{Y}_n .

Uskottavuuspäätelyä

Tilastollinen malli: Autoregressiivinen aikasarjamalli

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

- Havainto Y_i riippuu lineaarisesti edellisestä havainnosta Y_{i-1} ja ei-havaittavasta virhetermistä ε_i aivan kuten lineaarisessa (regressio)mallissa. Havaintojen riippuvuus on ilmeistä (ellei $\phi = 0$).

Uskottavuuspäätelyä

Tilastollinen malli: Autoregressiivinen aikasarjamalli

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

- Havainto Y_i riippuu lineaarisesti edellisestä havainnosta Y_{i-1} ja ei-havaittavasta virhetermistä ε_i aivan kuten lineaarisessa (regressio)mallissa. Havaintojen riippuvuus on ilmeistä (ellei $\phi = 0$).
- Havainnot eivät myöskään ole samoin jakautuneita:
 $Y_1 = \phi y_0 + \varepsilon_1$ ja $Y_2 = \phi^2 y_0 + \phi \varepsilon_1 + \varepsilon_2 \Rightarrow \text{Var}(Y_1) \neq \text{Var}(Y_2)$.

Uskottavuuspäätelyä

Tilastollinen malli: Autoregressiivinen aikasarjamalli

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

- Havainto Y_i riippuu lineaarisesti edellisestä havainnosta Y_{i-1} ja ei-havaittavasta virhetermistä ε_i aivan kuten lineaarisessa (regressio)mallissa. Havaintojen riippuvuus on ilmeistä (ellei $\phi = 0$).
- Havainnot eivät myöskään ole samoin jakautuneita:
 $Y_1 = \phi y_0 + \varepsilon_1$ ja $Y_2 = \phi^2 y_0 + \phi \varepsilon_1 + \varepsilon_2 \Rightarrow \text{Var}(Y_1) \neq \text{Var}(Y_2)$.
- Usein vaaditaan $|\phi| < 1$, kun taas $\sigma^2 > 0$ luonteva rajoite.

Uskottavuuspäätelyä

Tilastollinen malli: Autoregressiivinen aikasarjamalli

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

- Havainto Y_i riippuu lineaarisesti edellisestä havainnosta Y_{i-1} ja ei-havaittavasta virhetermistä ε_i aivan kuten lineaarisessa (regressio)mallissa. Havaintojen riippuvuus on ilmeistä (ellei $\phi = 0$).
- Havainnot eivät myöskään ole samoin jakautuneita:
 $Y_1 = \phi y_0 + \varepsilon_1$ ja $Y_2 = \phi^2 y_0 + \phi \varepsilon_1 + \varepsilon_2 \Rightarrow \text{Var}(Y_1) \neq \text{Var}(Y_2)$.
- Usein vaaditaan $|\phi| < 1$, kun taas $\sigma^2 > 0$ luonteva rajoite.
- Kun $|\phi| \geq 1$ parametrien estimointi- ja testiteoria ns. epästandardi, sillä tavanomaiset SLL:t ja KRL:t eivät päde.

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- Havainnot saatu N :stä riippumattomasta "yksilöstä" (esim. koehenkilö tai kotitalous) ja yksilölle j spesifioidaan (aluksi) lineaarinen regressiomalli

$$\begin{bmatrix} Y_{j,1} \\ \vdots \\ Y_{j,n_j} \end{bmatrix} = \alpha_j \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} + \gamma \begin{bmatrix} x_{j,1} \\ \vdots \\ x_{j,n_j} \end{bmatrix} + \begin{bmatrix} \varepsilon_{j,1} \\ \vdots \\ \varepsilon_{j,n_j} \end{bmatrix}$$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- Havainnot saatu N :stä riippumattomasta "yksilöstä" (esim. koehenkilö tai kotitalous) ja yksilölle j spesifioidaan (aluksi) lineaarinen regressiomalli

$$\begin{bmatrix} Y_{j,1} \\ \vdots \\ Y_{j,n_j} \end{bmatrix} = \alpha_j \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} + \gamma \begin{bmatrix} x_{j,1} \\ \vdots \\ x_{j,n_j} \end{bmatrix} + \begin{bmatrix} \varepsilon_{j,1} \\ \vdots \\ \varepsilon_{j,n_j} \end{bmatrix}$$

- tai

$$Y_j = \alpha_j \mathbf{1}_{n_j} + \gamma x_j + \varepsilon_j, \quad j = 1, \dots, N.$$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- Havainnot saatu N :stä riippumattomasta "yksilöstä" (esim. koehenkilö tai kotitalous) ja yksilölle j spesifioidaan (aluksi) lineaarinen regressiomalli

$$\begin{bmatrix} Y_{j,1} \\ \vdots \\ Y_{j,n_j} \end{bmatrix} = \alpha_j \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} + \gamma \begin{bmatrix} x_{j,1} \\ \vdots \\ x_{j,n_j} \end{bmatrix} + \begin{bmatrix} \varepsilon_{j,1} \\ \vdots \\ \varepsilon_{j,n_j} \end{bmatrix}$$

- tai

$$Y_j = \alpha_j \mathbf{1}_{n_j} + \gamma x_j + \varepsilon_j, \quad j = 1, \dots, N.$$

- Oletetaan

$$\varepsilon_1, \dots, \varepsilon_N \text{ \underline{\underline{||}} }, \quad \varepsilon_j \sim N(0, \sigma^2 I_{n_j}),$$

jolloin kaikki havainnot ovat riippumattomia.

- Malli

$$Y_j = Z_j \beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$$

jossa

$$Z_j = [\mathbf{1}_{n_j} : x_j] \quad (n_j \times 2) \quad \text{ja} \quad \beta = [\alpha \quad \gamma]'$$

$$\eta_j \sim N(0, \omega^2 J_{n_j} + \sigma^2 I_{n_j}) \quad \underline{\quad}, \quad J_{n_j} = \mathbf{1}_{n_j} \mathbf{1}'_{n_j} \quad \text{tunnettu}$$

- Malli

$$Y_j = Z_j \beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$$

jossa

$$Z_j = [\mathbf{1}_{n_j} : x_j] \quad (n_j \times 2) \quad \text{ja} \quad \beta = [\alpha \quad \gamma]'$$

$$\eta_j \sim N(0, \omega^2 J_{n_j} + \sigma^2 I_{n_j}) \quad \underline{\parallel}, \quad J_{n_j} = \mathbf{1}_{n_j} \mathbf{1}_{n_j}' \quad \text{tunnettu}$$

- Parametriavaruus määräytyy ehdoista $\beta \in \mathbb{R}^2$, $\sigma^2 > 0$ ja $\omega^2 \geq 0$.

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_j = Z_j\beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_j = Z_j\beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$
- $\eta_j \sim N(0, V_j(\omega^2, \sigma^2)) \quad \underline{\parallel}, \quad V_j(\omega^2, \sigma^2) = \omega^2 J_{n_j} + \sigma^2 I_{n_j}$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_j = Z_j \beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$
- $\eta_j \sim N(0, V_j(\omega^2, \sigma^2)) \quad \underline{\parallel}, \quad V_j(\omega^2, \sigma^2) = \omega^2 J_{n_j} + \sigma^2 I_{n_j}$
- Tilastollinen malli

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = \prod_{j=1}^N (2\pi)^{-n_j/2} \det(V_j(\omega^2, \sigma^2))^{-1/2} \\ \times \exp\left\{-\frac{1}{2} (y_j - Z_j \beta)' V_j(\omega^2, \sigma^2)^{-1} (y_j - Z_j \beta)\right\}$$

jossa $\theta = (\beta, \sigma^2, \omega^2) \in \mathbb{R}^2 \times (0, \infty) \times [0, \infty)$.

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistyksiä

- $$Y_j = Z_j\beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_j = Z_j\beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$
- $\eta_j \sim N(0, V_j(\omega^2, \sigma^2)) \quad \underline{\parallel}, \quad V_j(\omega^2, \sigma^2) = \omega^2 J_{n_j} + \sigma^2 I_{n_j}$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_j = Z_j\beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$
- $\eta_j \sim N(0, V_j(\omega^2, \sigma^2)) \quad \underline{\parallel}, \quad V_j(\omega^2, \sigma^2) = \omega^2 J_{n_j} + \sigma^2 I_{n_j}$
- Lisätään virhetermiin kolmas komponentti eli määritellään

$$\eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \xi_j + \varepsilon_j,$$

jossa $\xi_j \underline{\parallel}$ kahdesta muusta komponentista ja $\underline{\parallel}$ "yli j :n arvojen".

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_j = Z_j\beta + \eta_j, \quad \eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \varepsilon_j, \quad j = 1, \dots, N,$
- $\eta_j \sim N(0, V_j(\omega^2, \sigma^2)) \quad \underline{\underline{\quad}}, \quad V_j(\omega^2, \sigma^2) = \omega^2 J_{n_j} + \sigma^2 I_{n_j}$
- Lisätään virhetermiin kolmas komponentti eli määritellään

$$\eta_j = (\alpha_j - \alpha) \mathbf{1}_{n_j} + \zeta_j + \varepsilon_j,$$

jossa $\zeta_j \underline{\underline{\quad}}$ kahdesta muusta komponentista ja $\underline{\underline{\quad}}$ "yli j :n arvojen".

- Esim.

$$\zeta_{j,i} = \phi \zeta_{j,i-1} + \varepsilon_{j,i}, \quad i = 1, \dots, n_j, \quad \varepsilon_{j,i} \sim N(0, \lambda^2), \quad \lambda \geq 0, \quad \zeta_{j,0} = 0$$

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistystä

- $Y_1, \dots, Y_N \stackrel{\text{iid}}{\sim}, Y_j \sim N(Z_j\beta, V_j(\psi))$ ja

$V_j(\psi)$ on parametrivektorin ψ (tunnettua muotoa oleva) funktio \Rightarrow

Uskottavuuspäätelyä

Tilastollinen malli: Lineaarisen mallin yleistyksiä

- Y_1, \dots, Y_N iiid, $Y_j \sim N(Z_j\beta, V_j(\psi))$ ja

$V_j(\psi)$ on parametrivektorin ψ (tunnettua muotoa oleva) funktio \Rightarrow

-

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = \prod_{j=1}^N (2\pi)^{-n_j/2} \det(V_j(\psi))^{-1/2} \\ \times \exp\left\{-\frac{1}{2}(y_j - Z_j\beta)' V_j(\psi)^{-1} (y_j - Z_j\beta)\right\},$$

jossa $\theta = (\beta, \psi)$ ja matriisi Z_j voi sisältää useita selittäviä muuttujia.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori

- Aineisto $\mathbf{y} = (y_1, \dots, y_n)$, vast. sv $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori

- Aineisto $\mathbf{y} = (y_1, \dots, y_n)$, vast. sv $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$
- Määritelmän mukaan uskottavuusfunktio $L(\theta; \mathbf{y})$ on

$$L(\theta; \mathbf{y}) = c(\mathbf{y}) f_{\mathbf{Y}}(\mathbf{y}; \theta), \quad \theta \in \Theta \subseteq \mathbb{R}^d,$$

jossa $c(\mathbf{y}) > 0$ (myöhemmin usein $c(\mathbf{y}) = 1$).

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori

- Aineisto $\mathbf{y} = (y_1, \dots, y_n)$, vast. sv $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$

- Määritelmän mukaan uskottavuusfunktio $L(\theta; \mathbf{y})$ on

$$L(\theta; \mathbf{y}) = c(\mathbf{y}) f_{\mathbf{Y}}(\mathbf{y}; \theta), \quad \theta \in \Theta \subseteq \mathbb{R}^d,$$

jossa $c(\mathbf{y}) > 0$ (myöhemmin usein $c(\mathbf{y}) = 1$).

- Monissa tarkasteluissa käytetään logaritmoitua uskottavuusfunktioita

$$l(\theta; \mathbf{y}) = \log L(\theta; \mathbf{y}).$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori

- Aineisto $\mathbf{y} = (y_1, \dots, y_n)$, vast. sv $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja ytf/yptf $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$

- Määritelmän mukaan uskottavuusfunktio $L(\theta; \mathbf{y})$ on

$$L(\theta; \mathbf{y}) = c(\mathbf{y}) f_{\mathbf{Y}}(\mathbf{y}; \theta), \quad \theta \in \Theta \subseteq \mathbb{R}^d,$$

jossa $c(\mathbf{y}) > 0$ (myöhemmin usein $c(\mathbf{y}) = 1$).

- Monissa tarkasteluissa käytetään logaritmoitua uskottavuusfunktioita

$$l(\theta; \mathbf{y}) = \log L(\theta; \mathbf{y}).$$

- Kun aiheellista korostaa riippuvuutta havaintojen lukumäärästä, merkitään $L_n(\theta; \mathbf{y}_n)$ ja $l_n(\theta; \mathbf{y}_n)$.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja $Y_1, \dots, Y_n \underline{\underline{\text{||}}}$ ja $Y_i \sim f_{Y_i}(y_i; \theta) \Rightarrow$

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdots f_{Y_n}(y_n; \theta)$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja $Y_1, \dots, Y_n \underline{\underline{\parallel}}$ ja $Y_i \sim f_{Y_i}(y_i; \theta) \Rightarrow$

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdots f_{Y_n}(y_n; \theta)$$

- Merkitään $\mathbf{Y}_i = (Y_1, \dots, Y_i)$ ja $\mathbf{y}_i = (y_1, \dots, y_i)$, $i = 1, \dots, n$, joten aineistoa vastaavan sv:n \mathbf{Y}_n ytf/yptf on $f_{\mathbf{Y}_n}$.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja $Y_1, \dots, Y_n \underline{\underline{\parallel}}$ ja $Y_i \sim f_{Y_i}(y_i; \theta) \Rightarrow$

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdots f_{Y_n}(y_n; \theta)$$

- Merkitään $\mathbf{Y}_i = (Y_1, \dots, Y_i)$ ja $\mathbf{y}_i = (y_1, \dots, y_i)$, $i = 1, \dots, n$, joten aineistoa vastaavan sv:n \mathbf{Y}_n ytf/yptf on $f_{\mathbf{Y}_n}$.

- $\mathbf{Y}_i = (\mathbf{Y}_{i-1}, Y_i) \Rightarrow \dots \Rightarrow$ käyttäen ehd. tf:n/ptf:n määritelmää

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i|\mathbf{Y}_{i-1}}(y_i|\mathbf{y}_{i-1}; \theta)$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $\mathbf{Y} = (Y_1, \dots, Y_n)$ ja $Y_1, \dots, Y_n \underline{\parallel}$ ja $Y_i \sim f_{Y_i}(y_i; \theta) \Rightarrow$

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdots f_{Y_n}(y_n; \theta)$$

- Merkitään $\mathbf{Y}_i = (Y_1, \dots, Y_i)$ ja $\mathbf{y}_i = (y_1, \dots, y_i)$, $i = 1, \dots, n$, joten aineistoa vastaavan sv:n \mathbf{Y}_n ytf/yptf on $f_{\mathbf{Y}_n}$.

- $\mathbf{Y}_i = (\mathbf{Y}_{i-1}, Y_i) \Rightarrow \dots \Rightarrow$ käyttäen ehd. tf:n/ptf:n määritelmää

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i|\mathbf{Y}_{i-1}}(y_i|\mathbf{y}_{i-1}; \theta)$$

- Yleistää yo tapauksen tuloesityksen. Toimii periaatteessa aina.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$
- ja, kun $f_{i-1}(y_i; \theta) = f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$,

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$
- ja, kun $f_{i-1}(y_i; \theta) = f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$,
- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta)$,

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$

- ja, kun $f_{i-1}(y_i; \theta) = f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$,

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta)$,

- jossa merkintöjen ja ehdollisen tf:n/ptf:n määritelmän mukaan

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$

- ja, kun $f_{i-1}(y_i; \theta) = f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$,

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta)$,

- jossa merkintöjen ja ehdollisen tf:n/ptf:n määritelmän mukaan

- $f_{i-1}(y_i; \theta) = \frac{f_{\mathbf{Y}_{i-1}, Y_i}(\mathbf{y}_{i-1}, y_i; \theta)}{f_{\mathbf{Y}_{i-1}}(\mathbf{y}_{i-1}; \theta)}$ tai

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$

- ja, kun $f_{i-1}(y_i; \theta) = f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta)$,

- $f_{\mathbf{Y}}(\mathbf{y}; \theta) = f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta)$,

- jossa merkintöjen ja ehdollisen tf:n/ptf:n määritelmän mukaan

- $f_{i-1}(y_i; \theta) = \frac{f_{\mathbf{Y}_{i-1}, Y_i}(\mathbf{y}_{i-1}, y_i; \theta)}{f_{\mathbf{Y}_{i-1}}(\mathbf{y}_{i-1}; \theta)}$ tai

- $f_{i-1}(y_i; \theta) = \frac{f_{Y_1, \dots, Y_i}(y_1, \dots, y_i; \theta)}{f_{Y_1, \dots, Y_{i-1}}(y_1, \dots, y_{i-1}; \theta)}$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- Koska

$$\begin{aligned}f_{\mathbf{Y}}(\mathbf{y}; \theta) &= f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta) \\ &= f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta),\end{aligned}$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- Koska

$$\begin{aligned}f_{\mathbf{Y}}(\mathbf{y}; \theta) &= f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta) \\ &= f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta),\end{aligned}$$

- niin uskottavuusfunktiolle saadaan tuloesitys

$$L(\theta; \mathbf{y}) = c(\mathbf{y}) \cdot f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta)$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- Koska

$$\begin{aligned}f_{\mathbf{Y}}(\mathbf{y}; \theta) &= f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{Y_i | \mathbf{Y}_{i-1}}(y_i | \mathbf{y}_{i-1}; \theta) \\ &= f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta),\end{aligned}$$

- niin uskottavuusfunktiolle saadaan tuloesitys

$$L(\theta; \mathbf{y}) = c(\mathbf{y}) \cdot f_{Y_1}(y_1; \theta) \cdot \prod_{i=2}^n f_{i-1}(y_i; \theta)$$

- ja sen logaritmile vastavasti summaesitys

$$l(\theta; \mathbf{y}) = \log c(\mathbf{y}) + \log f_{Y_1}(y_1; \theta) + \sum_{i=2}^n \log f_{i-1}(y_i; \theta).$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- Tarkastellaan autoregresssiivistä aikasarjamallia

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- Tarkastellaan autoregressiivistä aikasarjamallia

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

- Havaintoja ytf:ksi saadaan $(\theta = (\phi, \sigma^2))$

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = \prod_{i=1}^n (2\pi\sigma^2)^{-1/2} \exp\left\{-\frac{1}{2\sigma^2} (y_i - \phi y_{i-1})^2\right\}$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Mallin tuloesitys

- Tarkastellaan autoregressiivistä aikasarjamallia

$$Y_i = \phi Y_{i-1} + \varepsilon_i, \quad i = 1, \dots, n, \quad Y_0 = y_0, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}}$$

- Havaintoja ytf:ksi saadaan $(\theta = (\phi, \sigma^2))$

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = \prod_{i=1}^n (2\pi\sigma^2)^{-1/2} \exp\left\{-\frac{1}{2\sigma^2} (y_i - \phi y_{i-1})^2\right\}$$

- tai

$$f_{\mathbf{Y}}(\mathbf{y}; \theta) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \phi y_{i-1})^2\right\}$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- *SU-estimaatti* $\hat{\theta} = \hat{\theta}(\mathbf{y})$ toteuttaa määritelmän mukaan ehdon

$$L(\hat{\theta}; \mathbf{y}) \geq L(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- *SU-estimaatti* $\hat{\theta} = \hat{\theta}(\mathbf{y})$ toteuttaa määritelmän mukaan ehdon

$$L(\hat{\theta}; \mathbf{y}) \geq L(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d$$

- tai yhtäpitävästi log-uskottavuusfunktion avulla ilmaistuna

$$l(\hat{\theta}; \mathbf{y}) \geq l(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d.$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU -estimaattori: SU -estimaattori

- SU -estimaatti $\hat{\theta} = \hat{\theta}(\mathbf{y})$ toteuttaa määritelmän mukaan ehdon

$$L(\hat{\theta}; \mathbf{y}) \geq L(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d$$

- tai yhtäpitävästi log-uskottavuusfunktion avulla ilmaistuna

$$l(\hat{\theta}; \mathbf{y}) \geq l(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d.$$

- Tulkittuna satunnaisena eli $\hat{\theta} = \hat{\theta}(\mathbf{Y})$ on $\hat{\theta}$ SU -estimaattori.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- *SU-estimaatti* $\hat{\theta} = \hat{\theta}(\mathbf{y})$ toteuttaa määritelmän mukaan ehdon

$$L(\hat{\theta}; \mathbf{y}) \geq L(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d$$

- tai yhtäpitävästi log-uskottavuusfunktion avulla ilmaistuna

$$l(\hat{\theta}; \mathbf{y}) \geq l(\theta; \mathbf{y}) \quad \text{kaikilla } \theta \in \Theta \subseteq \mathbb{R}^d.$$

- Tulkittuna satunnaisena eli $\hat{\theta} = \hat{\theta}(\mathbf{Y})$ on $\hat{\theta}$ *SU-estimaattori*.
- Jatkossa käytetään yleensä merkintää $\hat{\theta}$ tai $\hat{\theta}_n$.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.
- Matemaattisesti tämä ei ole itsestään selvää.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.
- Matemaattisesti tämä ei ole itsestään selvää.
- Mainitaan tiedoksi, että (eräät) riittävät ehdot ovat, että

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.
- Matemaattisesti tämä ei ole itsestään selvää.
- Mainitaan tiedoksi, että (eräät) riittävät ehdot ovat, että
 - uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on jatkuva kaikilla mahdollisilla aineistoilla \mathbf{y} ja

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.
- Matemaattisesti tämä ei ole itsestään selvää.
- Mainitaan tiedoksi, että (eräät) riittävät ehdot ovat, että
 - uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on jatkuva kaikilla mahdollisilla aineistoilla \mathbf{y} ja
 - parametriavaruus Θ on kompakti (eli suljettu ja rajoitettu).

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.
- Matemaattisesti tämä ei ole itsestään selvää.
- Mainitaan tiedoksi, että (eräät) riittävät ehdot ovat, että
 - uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on jatkuva kaikilla mahdollisilla aineistoilla \mathbf{y} ja
 - parametriavaruus Θ on kompakti (eli suljettu ja rajoitettu).
- Jatkossa SU-estimaattorin olemassaolo tullaan olettamaan, mikä ei kuitenkaan takaa yksikäsiteisyyttä.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: SU-estimaattori

- Edellä oletettiin, että uskottavuusfunktio todella saavuttaa maksimiarvonsa pisteessä $\hat{\theta}(\mathbf{y})$ ja että $\hat{\theta}(\mathbf{Y})$ on sm.
- Matemaattisesti tämä ei ole itsestään selvää.
- Mainitaan tiedoksi, että (eräät) riittävät ehdot ovat, että
 - uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on jatkuva kaikilla mahdollisilla aineistoilla \mathbf{y} ja
 - parametriavaruus Θ on kompakti (eli suljettu ja rajoitettu).
- Jatkossa SU-estimaattorin olemassaolo tullaan olettamaan, mikä ei kuitenkaan takaa yksikäsiteisyyttä.
- Useimmissa monimutkaisemmissa malleissa SU-estimaattia ei voida ratkaista suljetussa muodossa, vaan estimointi joudutaan suorittamaan numeerisia menetelmiä käyttäen.

- Usein aineiston havainnot on luontevaa jakaa kahteen komponenttiin eli aineisto on $\mathbf{w} = (w_1, \dots, w_n)$, jossa $w_i = (y_i, x_i)$, $i = 1, \dots, n$.

Ehdollinen malli ja margnaalimalli

- Usein aineiston havainnot on luontevaa jakaa kahteen komponenttiin eli aineisto on $\mathbf{w} = (w_1, \dots, w_n)$, jossa $w_i = (y_i, x_i)$, $i = 1, \dots, n$.
- Jako perustuu taustatietoon tai -teoriaan ja ideana on, että y -muuttujat ovat regressioanalyysin tapaan selitettäviä muuttujia ja x -muuttujat niiden vaihtelua selittäviä "syymuuttujia".

- Usein aineiston havainnot on luontevaa jakaa kahteen komponenttiin eli aineisto on $\mathbf{w} = (w_1, \dots, w_n)$, jossa $w_i = (y_i, x_i)$, $i = 1, \dots, n$.
- Jako perustuu taustatietoon tai -teoriaan ja ideana on, että y -muuttujat ovat regressioanalyysin tapaan selitettäviä muuttujia ja x -muuttujat niiden vaihtelua selittäviä "syytuuttujia".
- Kumpaankin muuttujaan ajatellaan liittyvän satunnaisvaihtelua (molempien havainnot on esimerkiksi saatu satunnaisotantaa käyttäen). Merkitään jälleen vastaavia satunnaismuuttujia suurilla kirjaimilla \mathbf{W} , W_i , Y_i ja X_i .

- Usein aineiston havainnot on luontevaa jakaa kahteen komponenttiin eli aineisto on $\mathbf{w} = (w_1, \dots, w_n)$, jossa $w_i = (y_i, x_i)$, $i = 1, \dots, n$.
- Jako perustuu taustatietoon tai -teoriaan ja ideana on, että y -muuttujat ovat regressioanalyysin tapaan selitettäviä muuttujia ja x -muuttujat niiden vaihtelua selittäviä "syymuuttujia".
- Kumpaankin muuttujaan ajatellaan liittyvän satunnaisvaihtelua (molempien havainnot on esimerkiksi saatu satunnaisotantaa käyttäen). Merkitään jälleen vastaavia satunnaismuuttujia suurilla kirjaimilla \mathbf{W} , W_i , Y_i ja X_i .
- Tällaisessa tilanteessa pääasiallinen mielenkiinto kohdistuu usein y -muuttujien riippuvuuteen x -muuttujista, jolloin y -muuttujia tuntuu luontevalta tarkastella ehdollistamalla x -muuttujien suhteen.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon $W_1, \dots, W_n \sim N_k(\mu, \Sigma)$ || . Ositetaan

$$W_i = \begin{bmatrix} Y_i \\ X_i \end{bmatrix} \quad \begin{matrix} 1 \\ k-1 \end{matrix} \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \text{ja} \quad \Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{bmatrix} .$$

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon $W_1, \dots, W_n \sim N_k(\mu, \Sigma)$. Ositetaan

$$W_i = \begin{bmatrix} Y_i \\ X_i \end{bmatrix} \quad \begin{matrix} 1 \\ k-1 \end{matrix} \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \text{ja} \quad \Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{bmatrix} .$$

- W_i :n ytf on $f_{W_i} = f_{Y_i|X_i} \cdot f_{X_i}$.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon $W_1, \dots, W_n \sim N_k(\mu, \Sigma)$ || . Ositetaan

$$W_i = \begin{bmatrix} Y_i \\ X_i \end{bmatrix} \quad \begin{matrix} 1 \\ k-1 \end{matrix} \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \text{ja} \quad \Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{bmatrix} .$$

- W_i :n ytf on $f_{W_i} = f_{Y_i|X_i} \cdot f_{X_i}$.
- MN-jakauman ominaisuuksien nojalla,

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon $W_1, \dots, W_n \sim N_k(\mu, \Sigma)$ || . Ositetaan

$$W_i = \begin{bmatrix} Y_i \\ X_i \end{bmatrix} \quad \begin{matrix} 1 \\ k-1 \end{matrix} \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \text{ja} \quad \Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{bmatrix} .$$

- W_i :n ytf on $f_{W_i} = f_{Y_i|X_i} \cdot f_{X_i}$.
- MN-jakauman ominaisuuksien nojalla,
 - $X_i \sim N_{k-1}(\mu_2, \Sigma_{22})$ ja

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon $W_1, \dots, W_n \sim N_k(\mu, \Sigma)$ || . Ositetaan

$$W_i = \begin{bmatrix} Y_i \\ X_i \end{bmatrix} \quad \begin{matrix} 1 \\ k-1 \end{matrix} \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \text{ja} \quad \Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{bmatrix}.$$

- W_i :n ytf on $f_{W_i} = f_{Y_i|X_i} \cdot f_{X_i}$.
- MN-jakauman ominaisuuksien nojalla,
 - $X_i \sim N_{k-1}(\mu_2, \Sigma_{22})$ ja
 - $Y_i | (X_i = x_i) \sim N(\mu_1 - \sigma_{12}\Sigma_{22}^{-1}(x_i - \mu_2), \sigma^2)$,
jossa $\sigma^2 = \sigma_1^2 - \sigma_{12}\Sigma_{22}^{-1}\sigma_{21}$.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon $W_1, \dots, W_n \sim N_k(\mu, \Sigma)$ || . Ositetaan

$$W_i = \begin{bmatrix} Y_i \\ X_i \end{bmatrix} \quad \begin{matrix} 1 \\ k-1 \end{matrix} \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \text{ja} \quad \Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \Sigma_{22} \end{bmatrix}.$$

- W_i :n ytf on $f_{W_i} = f_{Y_i|X_i} \cdot f_{X_i}$.
- MN-jakauman ominaisuuksien nojalla,
 - $X_i \sim N_{k-1}(\mu_2, \Sigma_{22})$ ja
 - $Y_i | (X_i = x_i) \sim N(\mu_1 - \sigma_{12}\Sigma_{22}^{-1}(x_i - \mu_2), \sigma^2)$,
jossa $\sigma^2 = \sigma_1^2 - \sigma_{12}\Sigma_{22}^{-1}\sigma_{21}$.
- Mielenkiinto kohdistuu ehdolliseen jakaumaan $Y_i | (X_i = x_i)$.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Kiinnostavassa ehdollisessa jakaumassa

$$Y_i | (X_i = x_i) \sim N(\mu_1 - \sigma_{12}\Sigma_{22}^{-1}(x_i - \mu_2), \sigma^2)$$

on varianssille otettu jo käyttöön uudelleen parametointi

$$\sigma^2 = \sigma_1^2 - \sigma_{12}\Sigma_{22}^{-1}\sigma_{21}.$$

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Kiinnostavassa ehdollisessa jakaumassa

$$Y_i | (X_i = x_i) \sim N(\mu_1 - \sigma_{12}\Sigma_{22}^{-1}(x_i - \mu_2), \sigma^2)$$

on varianssille otettu jo käyttöön uudelleen parametointi

$$\sigma^2 = \sigma_1^2 - \sigma_{12}\Sigma_{22}^{-1}\sigma_{21}.$$

- Samoin on luontevaa käyttää parametointia

$$\alpha = \mu_1 + \sigma_{12}\Sigma_{22}^{-1}\mu_2 \quad \text{ja} \quad \gamma' = -\sigma_{12}\Sigma_{22}^{-1},$$

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Kiinnostavassa ehdollisessa jakaumassa

$$Y_i | (X_i = x_i) \sim N(\mu_1 - \sigma_{12}\Sigma_{22}^{-1}(x_i - \mu_2), \sigma^2)$$

on varianssille otettu jo käyttöön uudelleen parametointi

$$\sigma^2 = \sigma_1^2 - \sigma_{12}\Sigma_{22}^{-1}\sigma_{21}.$$

- Samoin on luontevaa käyttää parametointia

$$\alpha = \mu_1 + \sigma_{12}\Sigma_{22}^{-1}\mu_2 \quad \text{ja} \quad \gamma' = -\sigma_{12}\Sigma_{22}^{-1},$$

- jolloin

$$Y_i | (X_i = x_i) \sim N(z_i'\beta, \sigma^2),$$

jossa $z_i = [1 \ x_i']'$ ja $\beta = [\alpha \ \gamma']'$ ovat $k \times 1$ vektoreita.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon ehd. jakauman $Y_i | (X_i = x_i) \sim N(z_i' \beta, \sigma^2)$ parametri $\psi = (\beta, \sigma^2)$ ja ehtomuuttujan $X_i \sim N_{k-1}(\mu_2, \Sigma_{22})$ parametri λ .

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon ehd. jakauman $Y_i | (X_i = x_i) \sim N(z_i' \beta, \sigma^2)$ parametri $\psi = (\beta, \sigma^2)$ ja ehtomuuttujan $X_i \sim N_{k-1}(\mu_2, \Sigma_{22})$ parametri λ .
- Riippumattomuuden nojalla saadaan tilastolliseksi malliksi

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = \prod_{i=1}^n f_{Y_i|X_i}(y_i|x_i; \psi) \times f_{X_i}(x_i; \lambda)$$

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Olkoon ehd. jakauman $Y_i | (X_i = x_i) \sim N(z_i' \beta, \sigma^2)$ parametri $\psi = (\beta, \sigma^2)$ ja ehtomuuttujan $X_i \sim N_{k-1}(\mu_2, \Sigma_{22})$ parametri λ .
- Riippumattomuuden nojalla saadaan tilastolliseksi malliksi

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = \prod_{i=1}^n f_{Y_i|X_i}(y_i|x_i; \psi) \times f_{X_i}(x_i; \lambda)$$

- eli

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2 \right\} \\ \times \prod_{i=1}^n f_{X_i}(x_i; \lambda),$$

jossa parametrit ψ ja λ vaihtelevat vapaasti ($\sigma^2 > 0$ ja $\Sigma_{22} > 0$).

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- $f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i'\beta)^2\right\} \times \prod_{i=1}^n f_{X_i}(x_i; \lambda)$

Ehdollinen malli ja marginaalimalli

Multinormaalijakaumaan perustuva esimerkki

- $f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i'\beta)^2\right\} \times \prod_{i=1}^n f_{X_i}(x_i; \lambda)$
- Jälkimmäinen tekijä oikealla eli sv:n $\mathbf{X} = (X_1, \dots, X_n)$ ytf on ns. *marginaalimalli*, josta ei olla kiinnostuneita.

Ehdollinen malli ja marginaalimalli

Multinormaalijakaumaan perustuva esimerkki

- $f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{z}'_i\beta)^2\right\} \times \prod_{i=1}^n f_{X_i}(x_i; \lambda)$
- Jälkimmäinen tekijä oikealla eli sv:n $\mathbf{X} = (X_1, \dots, X_n)$ ytf on ns. *marginaalimalli*, josta ei olla kiinnostuneita.
- Edellinen, ehd. jakaumiin $Y_i | (X_i = x_i) \sim N(\mathbf{z}'_i\beta, \sigma^2)$ perustuva tekijä, on ns. *ehdollinen malli*.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- $f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{z}'_i\beta)^2\right\} \times \prod_{i=1}^n f_{X_i}(x_i; \lambda)$
- Jälkimmäinen tekijä oikealla eli sv:n $\mathbf{X} = (X_1, \dots, X_n)$ ytf on ns. *marginaalimalli*, josta ei olla kiinnostuneita.
- Edellinen, ehd. jakaumiin $Y_i | (X_i = x_i) \sim N(\mathbf{z}'_i\beta, \sigma^2)$ perustuva tekijä, on ns. *ehdollinen malli*.
- Kun mielenkiinto kohdistuu ehd. mallin parametriin $\psi = (\beta, \sigma^2)$, voidaan marginaalimalli sivuuttaa ψ :sta riippumattomana tekijänä.

Ehdollinen malli ja marginaalimalli

Multinormaalijakaumaan perustuva esimerkki

- $f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i'\beta)^2\right\} \times \prod_{i=1}^n f_{X_i}(x_i; \lambda)$
- Jälkimmäinen tekijä oikealla eli sv:n $\mathbf{X} = (X_1, \dots, X_n)$ ytf on ns. *marginaalimalli*, josta ei olla kiinnostuneita.
- Edellinen, ehd. jakaumiin $Y_i | (X_i = x_i) \sim N(z_i'\beta, \sigma^2)$ perustuva tekijä, on ns. *ehdollinen malli*.
- Kun mielenkiinto kohdistuu ehd. mallin parametriin $\psi = (\beta, \sigma^2)$, voidaan marginaalimalli sivuuttaa ψ :sta riippumattomana tekijänä.
- ψ :aa koskeva päättely voidaan tällöin perustaa pelkästään ehd. malliin.

Ehdollinen malli ja marginaalimalli

Multinormaalijakaumaan perustuva esimerkki

- $f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i'\beta)^2\right\} \times \prod_{i=1}^n f_{X_i}(x_i; \lambda)$
- Jälkimmäinen tekijä oikealla eli sv:n $\mathbf{X} = (X_1, \dots, X_n)$ ytf on ns. *marginaalimalli*, josta ei olla kiinnostuneita.
- Edellinen, ehd. jakaumiin $Y_i | (X_i = x_i) \sim N(z_i'\beta, \sigma^2)$ perustuva tekijä, on ns. *ehdollinen malli*.
- Kun mielenkiinto kohdistuu ehd. mallin parametriin $\psi = (\beta, \sigma^2)$, voidaan marginaalimalli sivuuttaa ψ :sta riippumattomana tekijänä.
- ψ :aa koskeva päättely voidaan tällöin perustaa pelkästään ehd. malliin.
- Lisäksi, sv:n \mathbf{X} havainnot voidaan tulkita kiinteiksi ei-satunnaisiksi selittäviksi muuttujiksi kuten perinteisessä lineaarisessa mallissa.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Havaintojen jako komponentteihin perustuu ei-tilastollisiin argumentteihin.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Havaintojen jako komponentteihin perustuu ei-tilastollisiin argumentteihin.
- Selitettävää y -muuttujaa ei ole relevanttia tulkita x -muuttujaa tai mitään sen komponenttia selittäväksi "syy-muuttujaksi".

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Havaintojen jako komponentteihin perustuu ei-tilastollisiin argumentteihin.
- Selitettävää y -muuttujaa ei ole relevanttia tulkita x -muuttujaa tai mitään sen komponenttia selittäväksi "syymuuttujaksi".
- Jos y -muuttuja on x :n "syymuuttujaksi" eli "kausaalisuus" sekä suuntaan $x \rightarrow y$ että suuntaan $y \rightarrow x$ pätevät, johtaa edellä käytetty ehdollistaminen virheellisiin johtopäätöksiin.

Ehdollinen malli ja margnaalimalli

Multinormaalijakaumaan perustuva esimerkki

- Havaintojen jako komponentteihin perustuu ei-tilastollisiin argumentteihin.
- Selitettävää y -muuttujaa ei ole relevanttia tulkita x -muuttujaa tai mitään sen komponenttia selittäväksi "syymuuttujaksi".
- Jos y -muuttuja on x :n "syymuuttujaksi" eli "kausaalisuus" sekä suuntaan $x \rightarrow y$ että suuntaan $y \rightarrow x$ pätevät, johtaa edellä käytetty ehdollistaminen virheellisiin johtopäätöksiin.
- Tällaisessa tilanteessa y -muuttujaan tulisi sisällyttää ne x :n komponentit, jotka on aiheellista tulkita "selitettäväksi" muuttujiksi.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$ ja $f_{\mathbf{W}}(\mathbf{w}; \theta)$ sen ytf/yptf, jossa θ tuntematon parametrivektori.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$ ja $f_{\mathbf{W}}(\mathbf{w}; \theta)$ sen ytf/yptf, jossa θ tuntematon parametrivektori.
- Kuten jaksossa 2.2,

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{W_1}(w_1; \theta) \prod_{i=2}^n f_{W_i | \mathbf{w}_{i-1}}(w_i | \mathbf{w}_{i-1}; \theta).$$

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$ ja $f_{\mathbf{W}}(\mathbf{w}; \theta)$ sen ytf/yptf, jossa θ tuntematon parametrivektori.
- Kuten jaksossa 2.2,

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{W_1}(w_1; \theta) \prod_{i=2}^n f_{W_i | \mathbf{w}_{i-1}}(w_i | \mathbf{w}_{i-1}; \theta).$$

- Olkoon $W_i = (Y_i, X_i)$, jossa Y_i ja X_i kuten MN-esimerkissä.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$ ja $f_{\mathbf{W}}(\mathbf{w}; \theta)$ sen ytf/yptf, jossa θ tuntematon parametrivektori.
- Kuten jaksossa 2.2,

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{W_1}(w_1; \theta) \prod_{i=2}^n f_{W_i | \mathbf{w}_{i-1}}(w_i | \mathbf{w}_{i-1}; \theta).$$

- Olkoon $W_i = (Y_i, X_i)$, jossa Y_i ja X_i kuten MN-esimerkissä.
- Tällöin $f_{W_1} = f_{Y_1 | X_1} f_{X_1}$ ja

$$\begin{aligned} f_{\mathbf{W}}(\mathbf{w}; \theta) &= f_{Y_1 | X_1}(y_1 | x_1; \theta) \prod_{i=2}^n f_{Y_i | (\mathbf{w}_{i-1}, X_i)}(y_i | \mathbf{w}_{i-1}, x_i; \theta) \\ &\quad \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i | \mathbf{w}_{i-1}}(x_i | \mathbf{w}_{i-1}; \theta). \end{aligned}$$

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$ ja $f_{\mathbf{W}}(\mathbf{w}; \theta)$ sen ytf/yptf, jossa θ tuntematon parametrivektori.
- Kuten jaksossa 2.2,

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{W_1}(w_1; \theta) \prod_{i=2}^n f_{W_i | \mathbf{w}_{i-1}}(w_i | \mathbf{w}_{i-1}; \theta).$$

- Olkoon $W_i = (Y_i, X_i)$, jossa Y_i ja X_i kuten MN-esimerkissä.
- Tällöin $f_{W_1} = f_{Y_1 | X_1} f_{X_1}$ ja

$$\begin{aligned} f_{\mathbf{W}}(\mathbf{w}; \theta) &= f_{Y_1 | X_1}(y_1 | x_1; \theta) \prod_{i=2}^n f_{Y_i | (\mathbf{w}_{i-1}, X_i)}(y_i | \mathbf{w}_{i-1}, x_i; \theta) \\ &\quad \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i | \mathbf{w}_{i-1}}(x_i | \mathbf{w}_{i-1}; \theta). \end{aligned}$$

- Oikealla *ehdollinen malli* \times *marginaalimalli*.

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- *Ehdollinen malli* \times *Marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{Y_1|X_1}(y_1|x_1; \theta) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \theta) \\ \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \theta).$$

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- Ehdollinen malli \times Marginaalimalli:

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{Y_1|X_1}(y_1|x_1; \theta) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \theta) \\ \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \theta).$$

- Parametrivektori θ esiintyy molemmissa \Rightarrow tilastollista päättelyä ei voida yleisesti ottaen perustaa pelkästään ehdolliseen malliin menettämättä informaatiota.

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- Ehdollinen malli \times Marginaalimalli:

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{Y_1|X_1}(y_1|x_1; \theta) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \theta) \\ \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \theta).$$

- Parametrivektori θ esiintyy molemmissa \Rightarrow tilastollista päättelyä ei voida yleisesti ottaen perustaa pelkästään ehdolliseen malliin menettämättä informaatiota.
- Oletetaan MN-esimerkin mukainen tilanne: $\theta = (\psi, \lambda)$, jossa λ esiintyy vain marginaalimallissa ja ψ ehdollisessa mallissa.

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- Ehdollinen malli \times Marginaalimalli:

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{Y_1|X_1}(y_1|x_1; \theta) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \theta) \\ \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \theta).$$

- Parametrivektori θ esiintyy molemmissa \Rightarrow tilastollista päättelyä ei voida yleisesti ottaen perustaa pelkästään ehdolliseen malliin menettämättä informaatiota.
- Oletetaan MN-esimerkin mukainen tilanne: $\theta = (\psi, \lambda)$, jossa λ esiintyy vain marginaalimallissa ja ψ ehdollisessa mallissa.
- ψ ei saa riippua λ :sta, mutta ψ :n määritelmän yhteydessä on voitu käyttää uudelleen parametrintia.

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- Ehdollinen malli \times Marginaalimalli:

$$f_{\mathbf{W}}(\mathbf{w}; \theta) = f_{Y_1|X_1}(y_1|x_1; \theta) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \theta) \\ \times f_{X_1}(x_1; \theta) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \theta).$$

- Parametrivektori θ esiintyy molemmissa \Rightarrow tilastollista päättelyä ei voida yleisesti ottaen perustaa pelkästään ehdolliseen malliin menettämättä informaatiota.
- Oletetaan MN-esimerkin mukainen tilanne: $\theta = (\psi, \lambda)$, jossa λ esiintyy vain marginaalimallissa ja ψ ehdollisessa mallissa.
- ψ ei saa riippua λ :sta, mutta ψ :n määritelmän yhteydessä on voitu käyttää uudelleen parametrintia.
- Parametriavaruus on siten $\Psi \times \Lambda$

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Kun ψ esiintyy vain ehd. mallissa ja λ vain marginaalimallissa, saadaan malliksi

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Kun ψ esiintyy vain ehd. mallissa ja λ vain marginaalimallissa, saadaan malliksi

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

- Kun mielenkiinto kohdistuu vain ehd. mallin parametriin ψ , voidaan marginaalimalli tulkita parametrissa riippumatomaksi vakioksi.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Kun ψ esiintyy vain ehd. mallissa ja λ vain marginaalimallissa, saadaan malliksi

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

- Kun mielenkiinto kohdistuu vain ehd. mallin parametriin ψ , voidaan marginaalimalli tulkita parametrasta riippumattomaksi vakioksi.
- Tällöin päädytään ehdolliseen uskottavuusfunktioon (ilman vakiota)

$$L^{(c)}(\psi; \mathbf{w}) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi),$$

johon ψ :aa koskeva päättely voidaan perustaa menettämättä infoa.

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- *Ehdollinen malli* \times *Marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- *Ehdollinen malli* \times *Marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

- Kuten MN-esimerkissä, x -muuttujat a priori y -muuttujien vaihtelua selittäviä "syymuuttujia", mutta ei päinvastoin.

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- *Ehdollinen malli* \times *Marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

- Kuten MN-esimerkissä, x -muuttujat a priori y -muuttujien vaihtelua selittäviä "syytuuttujia", mutta ei päinvastoin.
- "Syytuuttujan" tulkinta ei yhtä selkeä kuin MN-esimerkissä, sillä $f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda)$ voi riippua muuttujista y_1, \dots, y_{i-1} .

Ehdollinen malli ja marginaalimalli

Yleinen tapaus

- *Ehdollinen malli* \times *Marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda.$$

- Kuten MN-esimerkissä, x -muuttujat a priori y -muuttujien vaihtelua selittäviä "syytuuttujia", mutta ei päinvastoin.
- "Syytuuttujan" tulkinta ei yhtä selkeä kuin MN-esimerkissä, sillä $f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda)$ voi riippua muuttujista y_1, \dots, y_{i-1} .
- Näin ei ole, jos $X_i|\mathbf{W}_{i-1} \stackrel{d}{=} X_i|\mathbf{X}_{i-1}$, $\mathbf{X}_{i-1} = (X_1, \dots, X_{i-1})$ ($i \geq 2$), jolloin sv:n \mathbf{X}_n havainnot voidaan tulkita ehdollisessa mallissa kiinteiksi selittäviksi muuttujiksi ja marginaalimallin tarkempi täsmennys jätetään usein tekemättä.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Seuraavassa ehdollista mallia sovelletaan lineaariseen malliin.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Seuraavassa ehdollista mallia sovelletaan lineaariseen malliin.
- Siinä kuten useissa muissakin erikoistapauksissa ehdolliset ytf:t $f_{Y_i | (\mathbf{w}_{i-1}, X_i)}(y_i | \mathbf{w}_{i-1}, x_i; \psi)$ (tai yptf:t) riippuvat vain kiinteästä määrästä vektorin $(\mathbf{w}_{i-1}, x_i) = (y_1, x_1, \dots, y_{i-1}, x_{i-1}, x_i)$ komponentteja (esim. vain x_i :stä ja y_{i-1} :stä).

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Seuraavassa ehdollista mallia sovelletaan lineaariseen malliin.
- Siinä kuten useissa muissakin erikoistapauksissa ehdolliset ytf:t $f_{Y_i | (\mathbf{w}_{i-1}, X_i)}(y_i | \mathbf{w}_{i-1}, x_i; \psi)$ (tai yptf:t) riippuvat vain kiinteästä määrästä vektorin $(\mathbf{w}_{i-1}, x_i) = (y_1, x_1, \dots, y_{i-1}, x_{i-1}, x_i)$ komponentteja (esim. vain x_i :stä ja y_{i-1} :stä).
- Esitetyt periaatteet eivät rajoitu lineaariseen malliin, vaan ovat relevantteja myös muissa malleissa, joissa on "selitettäviä" ja "selittäviä" muuttujia.

Ehdollinen malli ja margnaalimalli

Yleinen tapaus

- Seuraavassa ehdollista mallia sovelletaan lineaariseen malliin.
- Siinä kuten useissa muissakin erikoistapauksissa ehdolliset ytf:t $f_{Y_i | (\mathbf{w}_{i-1}, X_i)}(y_i | \mathbf{w}_{i-1}, x_i; \psi)$ (tai yptf:t) riippuvat vain kiinteästä määräst \grave{a} vektorin $(\mathbf{w}_{i-1}, x_i) = (y_1, x_1, \dots, y_{i-1}, x_{i-1}, x_i)$ komponentteja (esim. vain x_i :st \grave{a} ja y_{i-1} :st \grave{a}).
- Esitetyt periaatteet eivät rajoitu lineaariseen malliin, vaan ovat relevantteja my \ddot{o} s muissa malleissa, joissa on "selitett \ddot{a} v \ddot{a} " ja "selitt \ddot{a} v \ddot{a} " muuttujia.
- Esimerkkej \ddot{a} muista malleista ovat epälineaarinen regressiomalli ja yleistetyn lineaarisen mallin erikoistapaukset (mukaan lukien tapaukset, jossa y -muuttuja on vektori).

Ehdollinen malli ja marginaalimalli

Sovellus lineaariseen malliin

- Oletetaan tilanne *ehdollinen malli* \times *marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{w}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{w}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda$$

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Oletetaan tilanne *ehdollinen malli* \times *marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{W}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{W}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda$$

- ja

$$Y_i|(\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i|Z_i \quad \text{ja} \quad Y_i|(Z_i = z_i) \sim N(z_i'\beta, \sigma^2),$$

jossa Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit.

Ehdollinen malli ja marginaalimalli

Sovellus lineaariseen malliin

- Oletetaan tilanne *ehdollinen malli* \times *marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{W}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{W}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda$$

- ja

$$Y_i|(\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i|Z_i \quad \text{ja} \quad Y_i|(Z_i = z_i) \sim N(z_i'\beta, \sigma^2),$$

jossa Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit.

- Kysymyksessä on siis normaalin lineaarinen regressiomalli.

Ehdollinen malli ja marginaalimalli

Sovellus lineaariseen malliin

- Oletetaan tilanne *ehdollinen malli* \times *marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{W}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{W}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda$$

- ja

$$Y_i|(\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i|Z_i \quad \text{ja} \quad Y_i|(Z_i = z_i) \sim N(z_i'\beta, \sigma^2),$$

jossa Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit.

- Kysymyksessä on siis normaalin lineaarinen regressiomalli.
- Konkreettisuuden vuoksi tarkastellaan kahta tapausta:

Ehdollinen malli ja marginaalimalli

Sovellus lineaariseen malliin

- Oletetaan tilanne *ehdollinen malli* \times *marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{W}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{W}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda$$

- ja

$$Y_i|(\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i|Z_i \quad \text{ja} \quad Y_i|(Z_i = z_i) \sim N(z_i'\beta, \sigma^2),$$

jossa Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit.

- Kysymyksessä on siis normaalin lineaarinen regressiomalli.
- Konkreettisuuden vuoksi tarkastellaan kahta tapausta:
 - $Z_i = (1, X_i)$ eli "tavanomaiseen" regressiomallia ja

Ehdollinen malli ja marginaalimalli

Sovellus lineaariseen malliin

- Oletetaan tilanne *ehdollinen malli* \times *marginaalimalli*:

$$f_{\mathbf{W}}(\mathbf{w}; \psi, \lambda) = f_{Y_1|X_1}(y_1|x_1; \psi) \prod_{i=2}^n f_{Y_i|(\mathbf{W}_{i-1}, X_i)}(y_i|\mathbf{w}_{i-1}, x_i; \psi) \\ \times f_{X_1}(x_1; \lambda) \prod_{i=2}^n f_{X_i|\mathbf{W}_{i-1}}(x_i|\mathbf{w}_{i-1}; \lambda), \quad (\psi, \lambda) \in \Psi \times \Lambda$$

- ja

$$Y_i|(\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i|Z_i \quad \text{ja} \quad Y_i|(Z_i = z_i) \sim N(z_i'\beta, \sigma^2),$$

jossa Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit.

- Kysymyksessä on siis normaalin lineaarinen regressiomalli.
- Konkreettisuuden vuoksi tarkastellaan kahta tapausta:
 - $Z_i = (1, X_i)$ eli "tavanomaiseen" regressiomallia ja
 - $Z_i = (1, Y_{i-1}, X_i)$ eli autoregressiivinen aikasarjamalli ulkopuolisin selittävin muuttujin ($Y_0 = y_0$ tunnettu vakio).

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Koska

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

saadaan ehdolliseksi uskottavuusfunktiksi ($\beta \in \mathbb{R}^p, \sigma^2 > 0$)

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = \prod_{i=1}^n (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{1}{2\sigma^2} (y_i - z_i' \beta)^2 \right\}.$$

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Koska

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

saadaan ehdolliseksi uskottavuusfunktiksi ($\beta \in \mathbb{R}^p, \sigma^2 > 0$)

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = \prod_{i=1}^n (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{1}{2\sigma^2} (y_i - z_i' \beta)^2 \right\}.$$

- Nähdään, että ehdollinen malli voidaan esittää myös käyttäen yhtälöä

$$Y_i = Z_i' \beta + \varepsilon_i, \quad i = 1, \dots, n,$$

jossa $\varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2)$ || ja (\mathbf{W}_{i-1}, X_i) || $\varepsilon_i, i = 1, \dots, n$.

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Koska

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

saadaan ehdolliseksi uskottavuusfunktiksi ($\beta \in \mathbb{R}^p, \sigma^2 > 0$)

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = \prod_{i=1}^n (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{1}{2\sigma^2} (y_i - z_i' \beta)^2 \right\}.$$

- Nähdään, että ehdollinen malli voidaan esittää myös käyttäen yhtälöä

$$Y_i = Z_i' \beta + \varepsilon_i, \quad i = 1, \dots, n,$$

jossa $\varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2)$ || ja (\mathbf{W}_{i-1}, X_i) || $\varepsilon_i, i = 1, \dots, n$.

- Tämä otetaan usein mallin lähtökohdaksi.

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Mallin määrittely voidaan siis perustaa yhtälöön

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Mallin määrittely voidaan siis perustaa yhtälöön

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Mallin johtaminen ehdollista- ja marginaalimallia käyttäen osoittaa kuitenkin, mitä satunnaisten selittäjien tapauksessa täytyy olettaa, jotta mallia voidaan käyttää ajatellulla tavalla.

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Mallin määrittely voidaan siis perustaa yhtälöön

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Mallin johtaminen ehdollista- ja marginaalimallia käyttäen osoittaa kuitenkin, mitä satunnaisten selittäjien tapauksessa täytyy olettaa, jotta mallia voidaan käyttää ajatellulla tavalla.
- Esimerkiksi tapauksessa $Z_i = (1, X_i)$ oletetaan selittävät muuttujat X_i usein kiinteiksi perinteisen lineaarisen mallin tapaan.

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Mallin määrittely voidaan siis perustaa yhtälöön

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Mallin johtaminen ehdollista- ja marginaalimallia käyttäen osoittaa kuitenkin, mitä satunnaisten selittäjien tapauksessa täytyy olettaa, jotta mallia voidaan käyttää ajatellulla tavalla.
- Esimerkiksi tapauksessa $Z_i = (1, X_i)$ oletetaan selittävät muuttujat X_i usein kiinteiksi perinteisen lineaarisen mallin tapaan.
 - Tämä on loogista, jos $X_i | \mathbf{W}_{i-1} \stackrel{d}{=} X_i | \mathbf{X}_{i-1}$,

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin

- Mallin määrittely voidaan siis perustaa yhtälöön

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Mallin johtaminen ehdollista- ja marginaalimallia käyttäen osoittaa kuitenkin, mitä satunnaisten selittäjien tapauksessa täytyy olettaa, jotta mallia voidaan käyttää ajatellulla tavalla.
- Esimerkiksi tapauksessa $Z_i = (1, X_i)$ oletetaan selittävät muuttujat X_i usein kiinteiksi perinteisen lineaarisen mallin tapaan.
 - Tämä on loogista, jos $X_i | \mathbf{W}_{i-1} \stackrel{d}{=} X_i | \mathbf{X}_{i-1}$,
 - mutta ei, jos X_i riippuu esimerkiksi satunnaisesti tulkitusta Y_{i-1} :stä ja siten myös ε_{i-1} :stä. Tällöin tavanomainen lineaarisen mallin eksakti jakaumateoria ei päde.

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin: Parametrien estimointi

- Ehdollinen uskottavuusfunktio on muodollisesti samanlainen kuin tavanomaisessa lineaarisessa mallissa eli

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{z}_i' \beta)^2 \right\},$$

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin: Parametrien estimointi

- Ehdollinen uskottavuusfunktio on muodollisesti samanlainen kuin tavanomaisessa lineaarisessa mallissa eli

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{z}_i' \beta)^2 \right\},$$

- josta ehd. log-uskottavuusfunktio $l^{(c)}(\beta, \sigma^2; \mathbf{w}) = \log L^{(c)}(\beta, \sigma^2; \mathbf{w})$:

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{z}_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

Ehdollinen malli ja margnaalimalli

Sovellus lineaariseen malliin: Parametrien estimointi

- Ehdollinen uskottavuusfunktio on muodollisesti samanlainen kuin tavanomaisessa lineaarisessa mallissa eli

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2 \right\},$$

- josta ehd. log-uskottavuusfunktio $l^{(c)}(\beta, \sigma^2; \mathbf{w}) = \log L^{(c)}(\beta, \sigma^2; \mathbf{w})$:

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

- Lineaaristen mallien kurssi \Rightarrow SU-estimaattorit

$$\hat{\beta} = \left(\sum_{i=1}^n z_i z_i' \right)^{-1} \sum_{i=1}^n z_i y_i \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - z_i' \hat{\beta})^2.$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Oletetaan, että uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on kahdesti jatkuvasti derivoituva jokaisella \mathbf{y} . [$I(\theta; \mathbf{y}) = \log L(\theta; \mathbf{y})$]

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Oletetaan, että uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on kahdesti jatkuvasti derivoituva jokaisella \mathbf{y} . [$I(\theta; \mathbf{y}) = \log L(\theta; \mathbf{y})$]
- *Pistemääräfunktio* tai *pistemäärä* on

$$s(\theta; \mathbf{y}) := \frac{\partial}{\partial \theta} I(\theta; \mathbf{y}) = \left(\frac{\partial}{\partial \theta_1} I(\theta; \mathbf{y}), \dots, \frac{\partial}{\partial \theta_d} I(\theta; \mathbf{y}) \right)$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Oletetaan, että uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on kahdesti jatkuvasti derivoituva jokaisella \mathbf{y} . [$l(\theta; \mathbf{y}) = \log L(\theta; \mathbf{y})$]
- *Pistemääräfunktio* tai *pistemäärä* on

$$s(\theta; \mathbf{y}) := \frac{\partial}{\partial \theta} l(\theta; \mathbf{y}) = \left(\frac{\partial}{\partial \theta_1} l(\theta; \mathbf{y}), \dots, \frac{\partial}{\partial \theta_d} l(\theta; \mathbf{y}) \right)$$

- *Havaittu informaatio(matriisi)*

$$\mathcal{J}(\theta; \mathbf{y}) := -\frac{\partial^2}{\partial \theta \partial \theta'} l(\theta; \mathbf{y}) = \left[-\frac{\partial^2}{\partial \theta_a \partial \theta_b} l(\theta; \mathbf{y}) \right]_{a,b=1}^d$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Oletetaan, että uskottavuusfunktio $\theta \mapsto L(\theta; \mathbf{y})$ on kahdesti jatkuvasti derivoituva jokaisella \mathbf{y} . [$I(\theta; \mathbf{y}) = \log L(\theta; \mathbf{y})$]

- *Pistemääräfunktio* tai *pistemäärä* on

$$s(\theta; \mathbf{y}) := \frac{\partial}{\partial \theta} I(\theta; \mathbf{y}) = \left(\frac{\partial}{\partial \theta_1} I(\theta; \mathbf{y}), \dots, \frac{\partial}{\partial \theta_d} I(\theta; \mathbf{y}) \right)$$

- *Havaittu informaatio(matriisi)*

$$\mathcal{J}(\theta; \mathbf{y}) := -\frac{\partial^2}{\partial \theta \partial \theta'} I(\theta; \mathbf{y}) = \left[-\frac{\partial^2}{\partial \theta_a \partial \theta_b} I(\theta; \mathbf{y}) \right]_{a,b=1}^d$$

- *Fisherin informaatio(matriisi)*

$$\mathcal{I}(\theta) := \mathbb{E}[\mathcal{J}(\theta; \mathbf{Y})] = \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} I(\theta; \mathbf{Y}) \right],$$

jossa odotusarvon äärellisyys sisältyy määritelmään.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Log-uskottavuusfunktiolle todettu summaesitys ($c(\mathbf{y}) = 1$)

$$l(\theta; \mathbf{y}) = \sum_{i=1}^n \log f_{i-1}(y_i; \theta), \quad f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Log-uskottavuusfunktiolle todettu summaesitys ($c(\mathbf{y}) = 1$)

$$l(\theta; \mathbf{y}) = \sum_{i=1}^n \log f_{i-1}(y_i; \theta), \quad f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$$

- Siis, pistemäärä $s(\theta; \mathbf{y}) = \partial l(\theta; \mathbf{y}) / \partial \theta$ voidaan kirjoittaa

$$s(\theta; \mathbf{y}) = \sum_{i=1}^n u_i(\theta; y_i), \quad u_i(\theta; y_i) = \frac{\partial}{\partial \theta} \log f_{i-1}(y_i; \theta).$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Log-uskottavuusfunktiolle todettu summaesitys ($c(\mathbf{y}) = 1$)

$$l(\theta; \mathbf{y}) = \sum_{i=1}^n \log f_{i-1}(y_i; \theta), \quad f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$$

- Siis, pistemäärä $s(\theta; \mathbf{y}) = \partial l(\theta; \mathbf{y}) / \partial \theta$ voidaan kirjoittaa

$$s(\theta; \mathbf{y}) = \sum_{i=1}^n u_i(\theta; y_i), \quad u_i(\theta; y_i) = \frac{\partial}{\partial \theta} \log f_{i-1}(y_i; \theta).$$

- Vastaavasti havaittu informaatio

$$\mathcal{J}(\theta; \mathbf{y}) = - \sum_{i=1}^n \frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(y_i; \theta)$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Log-uskottavuusfunktiolle todettu summaesitys ($c(\mathbf{y}) = 1$)

$$l(\theta; \mathbf{y}) = \sum_{i=1}^n \log f_{i-1}(y_i; \theta), \quad f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$$

- Siis, pistemäärä $s(\theta; \mathbf{y}) = \partial l(\theta; \mathbf{y}) / \partial \theta$ voidaan kirjoittaa

$$s(\theta; \mathbf{y}) = \sum_{i=1}^n u_i(\theta; y_i), \quad u_i(\theta; y_i) = \frac{\partial}{\partial \theta} \log f_{i-1}(y_i; \theta).$$

- Vastaavasti havaittu informaatio

$$\mathcal{J}(\theta; \mathbf{y}) = - \sum_{i=1}^n \frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(y_i; \theta)$$

- ja Fisherin informaatio

$$\mathcal{I}(\theta) = - \sum_{i=1}^n \mathbb{E} \left[\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(\mathbf{Y}_i; \theta) \right].$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Tilastollisen päättelyn kurssilla on todettu, että ns. säännöllisissä malleissa pistemäärän $s(\theta; \mathbf{Y})$ odotusarvo on nolla eli

$$E[s(\theta; \mathbf{Y})] = 0$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Tilastollisen päätelyn kurssilla on todettu, että ns. säännöllisissä malleissa pistemäärän $s(\theta; \mathbf{Y})$ odotusarvo on nolla eli

$$E[s(\theta; \mathbf{Y})] = 0$$

- ja kovarianssimatriisi on Fisherin informaatiomatriisi $\mathcal{I}(\theta)$ eli

$$\text{Cov}[s(\theta; \mathbf{Y})] = E[s(\theta; \mathbf{Y}) s(\theta; \mathbf{Y})'] = \mathcal{I}(\theta).$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- Tilastollisen päättelyn kurssilla on todettu, että ns. säännöllisissä malleissa pistemäärän $s(\theta; \mathbf{Y})$ odotusarvo on nolla eli

$$E[s(\theta; \mathbf{Y})] = 0$$

- ja kovarianssimatriisi on Fisherin informaatiomatriisi $\mathcal{I}(\theta)$ eli

$$\text{Cov}[s(\theta; \mathbf{Y})] = E[s(\theta; \mathbf{Y}) s(\theta; \mathbf{Y})'] = \mathcal{I}(\theta).$$

- Lisäksi, Fisherin informaatiomatriisin avulla voidaan vastata kysymykseen kuinka tarkasti mallin parametria θ tai sen funktiota voidaan estimoida.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- *Informaatioepäyhtälö*: Parametrivektorin θ mille tahansa harhattomalle estimaattorille $T = t(\mathbf{Y})$ pätee

$$\text{Var}(a' T) = a' \text{Cov}(T) a \geq a' \mathcal{I}(\theta)^{-1} a \quad \text{kaikilla } a \in \mathbb{R}^d$$

tai

$$\text{Cov}(T) - \mathcal{I}(\theta)^{-1} \geq 0 \quad (\text{posit. semidefiniitti}).$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- *Informaatioepäyhtälö*: Parametrivektorin θ mille tahansa harhattomalle estimaattorille $T = t(\mathbf{Y})$ pätee

$$\text{Var}(a' T) = a' \text{Cov}(T) a \geq a' \mathcal{I}(\theta)^{-1} a \quad \text{kaikilla } a \in \mathbb{R}^d$$

tai

$$\text{Cov}(T) - \mathcal{I}(\theta)^{-1} \geq 0 \quad (\text{posit. semidefiniitti}).$$

- Jos epäyhtälön paikalla on yhtälö, pätee $\text{Cov}(T) = \mathcal{I}(\theta)^{-1}$ ja estimaattori T on täystehokas.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemääräfunktio ja informaatio

- *Informaatioepäyhtälö*: Parametrivektorin θ mille tahansa harhattomalle estimaattorille $T = t(\mathbf{Y})$ pätee

$$\text{Var}(a' T) = a' \text{Cov}(T) a \geq a' \mathcal{I}(\theta)^{-1} a \quad \text{kaikilla } a \in \mathbb{R}^d$$

tai

$$\text{Cov}(T) - \mathcal{I}(\theta)^{-1} \geq 0 \quad (\text{posit. semidefiniitti}).$$

- Jos epäyhtälön paikalla on yhtälö, pätee $\text{Cov}(T) = \mathcal{I}(\theta)^{-1}$ ja estimaattori T on täystehokas.
- SU-estimaattori on todettu täystehokkaaksi "suurissa otoksissa" ja "riittävien säännöllisyyssehtojen vallitessa", sillä tällöin

$$\hat{\theta}_{as} \sim N(\theta, \mathcal{I}(\theta)^{-1}).$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Ositetaan mallin $f_{\mathbf{Y}}(\mathbf{y}; \theta)$ parametrivektori kahteen (mahdollisesti vektoriarvoiseen) komponenttiin: $\theta = (\psi, \lambda)$.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Ositetaan mallin $f_{\mathbf{Y}}(\mathbf{y}; \theta)$ parametrivektori kahteen (mahdollisesti vektoriarvoiseen) komponenttiin: $\theta = (\psi, \lambda)$.
- Kuten tilastollisen päätelyn kurssilla, ovat parametrit ψ ja λ määritelmän mukaan *ortogonaalisia*, jos Fisherin informaatiomatriisi

$$\mathcal{I}(\theta) = \begin{bmatrix} \mathcal{I}_{\psi\psi}(\theta) & \mathcal{I}_{\psi\lambda}(\theta) \\ \mathcal{I}_{\lambda\psi}(\theta) & \mathcal{I}_{\lambda\lambda}(\theta) \end{bmatrix}$$

on lohkodeagonaalinen.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Ositetaan mallin $f_{\mathbf{Y}}(\mathbf{y}; \theta)$ parametrivektori kahteen (mahdollisesti vektoriarvoiseen) komponenttiin: $\theta = (\psi, \lambda)$.
- Kuten tilastollisen päätelyn kurssilla, ovat parametrit ψ ja λ määritelmän mukaan *ortogonaalisia*, jos Fisherin informaatiomatriisi

$$\mathcal{I}(\theta) = \begin{bmatrix} \mathcal{I}_{\psi\psi}(\theta) & \mathcal{I}_{\psi\lambda}(\theta) \\ \mathcal{I}_{\lambda\psi}(\theta) & \mathcal{I}_{\lambda\lambda}(\theta) \end{bmatrix}$$

on lohkodeagonaalinen.

- Toisin sanoen, ortogonaalisuus pätee, kun

$$\mathcal{I}_{\psi\lambda}(\theta) = \mathcal{I}_{\lambda\psi}(\theta)' = \mathbb{E} \left[-\frac{\partial^2}{\partial\psi\partial\lambda'} \ell(\theta; \mathbf{Y}) \right] = 0.$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Parametrien ortogonaalisuus on hyödyllinen ominaisuus, sillä sen voimassa ollessa parametreja ψ ja λ koskevat estimointi- ja testaustarkastelut ovat (suurissa otoksissa) likimain riippumattomia.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Parametrien ortogonaalisuus on hyödyllinen ominaisuus, sillä sen voimassa ollessa parametreja ψ ja λ koskevat estimointi- ja testaustarkastelut ovat (suurissa otoksissa) likimain riippumattomia.
- Intuitiivisesti: Parametria λ koskevat päätelmät ovat eivät vaikuta parametria ψ koskeviin päätelmiin (ja päinvastoin).

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Parametrien ortogonaalisuus on hyödyllinen ominaisuus, sillä sen voimassa ollessa parametreja ψ ja λ koskevat estimointi- ja testaustarkastelut ovat (suurissa otoksissa) likimain riippumattomia.
- Intuitiivisesti: Parametria λ koskevat päätelmät ovat eivät vaikuta parametria ψ koskeviin päätelmiin (ja päinvastoin).
- Usein toinen parametreista kiinnostava ja toinen kiusa- tai haittaparametri.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Parametrien ortogonaalisuus on hyödyllinen ominaisuus, sillä sen voimassa ollessa parametreja ψ ja λ koskevat estimointi- ja testaustarkastelut ovat (suurissa otoksissa) likimain riippumattomia.
- Intuitiivisesti: Parametria λ koskevat päätelmät ovat eivät vaikuta parametria ψ koskeviin päätelmiin (ja päinvastoin).
- Usein toinen parametreista kiinnostava ja toinen kiusa- tai haittaparametri.
- Ortogonaalisuuden määritelmää käyttäen nähdään helposti, että ehdollisen mallin ja marginaalimallin parametrit ψ ja λ ovat ortogonaaliset (perustelu jätetään tehtäväksi).

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Edellä tarkastellun lineaarisen mallin uskottavuusfunktio on

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2 \right\} \quad (\beta \in \mathbb{R}^p, \sigma^2 > 0)$$

josta log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2.$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Parametrien ortogonaalisuus

- Edellä tarkastellun lineaarisen mallin uskottavuusfunktio on

$$L^{(c)}(\beta, \sigma^2; \mathbf{w}) = (\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2 \right\} \quad (\beta \in \mathbb{R}^p, \sigma^2 > 0)$$

josta log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2.$$

- Derivointi:

$$\frac{\partial}{\partial \beta} l^{(c)}(\beta, \sigma^2; \mathbf{w}) = \frac{1}{\sigma^2} \sum_{i=1}^n z_i (y_i - z_i' \beta)$$

$$\frac{\partial}{\partial \sigma^2} l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (y_i - z_i' \beta)^2$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: **Säännölliset mallit**

- Jatkuva malli $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$, on *säännöllinen*, jos ($\forall n \geq 1$):

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: **Säännölliset mallit**

- Jatkuva malli $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$, on *säännöllinen*, jos ($\forall n \geq 1$):
- (a) jakauman alusta eli joukko $A = \{\mathbf{y} : f_{\mathbf{Y}}(\mathbf{y}; \theta) > 0\}$ ei riipu θ :sta,

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Säännölliset mallit

- Jatkuva malli $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$, on *säännöllinen*, jos ($\forall n \geq 1$):
 - (a) jakauman alusta eli joukko $A = \{\mathbf{y} : f_{\mathbf{Y}}(\mathbf{y}; \theta) > 0\}$ ei riipu θ :sta,
 - (b) funktiolla $\theta \mapsto f_{\mathbf{Y}}(\mathbf{y}; \theta)$ on jatkuvat 2. os. derivaatat jokaisella \mathbf{y} ,

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Säännölliset mallit

- Jatkuva malli $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$, on *säännöllinen*, jos ($\forall n \geq 1$):
 - (a) jakauman alusta eli joukko $A = \{\mathbf{y} : f_{\mathbf{Y}}(\mathbf{y}; \theta) > 0\}$ ei riipu θ :sta,
 - (b) funktiolla $\theta \mapsto f_{\mathbf{Y}}(\mathbf{y}; \theta)$ on jatkuvat 2. os. derivaatat jokaisella \mathbf{y} ,
 - (c) aina kun $T = t(\mathbf{Y})$ on tunnusluku, jolle $E_{\theta}(T)$ on olemassa kaikilla θ , pätee

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: **Säännölliset mallit**

- Jatkuva malli $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$, on *säännöllinen*, jos ($\forall n \geq 1$):
 - (a) jakauman alusta eli joukko $A = \{\mathbf{y} : f_{\mathbf{Y}}(\mathbf{y}; \theta) > 0\}$ ei riipu θ :sta,
 - (b) funktiolla $\theta \mapsto f_{\mathbf{Y}}(\mathbf{y}; \theta)$ on jatkuvat 2. os. derivaatat jokaisella \mathbf{y} ,
 - (c) aina kun $T = t(\mathbf{Y})$ on tunnusluku, jolle $E_{\theta}(T)$ on olemassa kaikilla θ , pätee

-

$$\frac{\partial}{\partial \theta_a} \int t(\mathbf{y}) f_{\mathbf{Y}}(\mathbf{y}; \theta) d\mathbf{y} = \int t(\mathbf{y}) \frac{\partial}{\partial \theta_a} f_{\mathbf{Y}}(\mathbf{y}; \theta) d\mathbf{y}, \quad a = 1, \dots, d,$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Säännölliset mallit

- Jatkuva malli $f_{\mathbf{Y}}(\mathbf{y}; \theta)$, $\theta \in \Theta \subseteq \mathbb{R}^d$, on *säännöllinen*, jos ($\forall n \geq 1$):
 - (a) jakauman alusta eli joukko $A = \{\mathbf{y} : f_{\mathbf{Y}}(\mathbf{y}; \theta) > 0\}$ ei riipu θ :sta,
 - (b) funktiolla $\theta \mapsto f_{\mathbf{Y}}(\mathbf{y}; \theta)$ on jatkuvat 2. os. derivaatat jokaisella \mathbf{y} ,
 - (c) aina kun $T = t(\mathbf{Y})$ on tunnusluku, jolle $E_{\theta}(T)$ on olemassa kaikilla θ , pätee

-

$$\frac{\partial}{\partial \theta_a} \int t(\mathbf{y}) f_{\mathbf{Y}}(\mathbf{y}; \theta) d\mathbf{y} = \int t(\mathbf{y}) \frac{\partial}{\partial \theta_a} f_{\mathbf{Y}}(\mathbf{y}; \theta) d\mathbf{y}, \quad a = 1, \dots, d,$$

- ja

$$(d) \quad \frac{\partial^2}{\partial \theta_a \partial \theta_b} \int f_{\mathbf{Y}}(\mathbf{y}; \theta) d\mathbf{y} = \int \frac{\partial^2}{\partial \theta_a \partial \theta_b} f_{\mathbf{Y}}(\mathbf{y}; \theta) d\mathbf{y}, \quad a, b = 1, \dots, d,$$

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemäärän ominaisuuksia

- Käytetään merkintöjä $s_n(\theta; \mathbf{y}_n) = \partial l_n(\theta; \mathbf{y}_n) / \partial \theta$ ja $\mathcal{I}_n(\theta)$.

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemäärän ominaisuuksia

- Käytetään merkintöjä $s_n(\theta; \mathbf{y}_n) = \partial l_n(\theta; \mathbf{y}_n) / \partial \theta$ ja $\mathcal{I}_n(\theta)$.
- **Lause 2.1.** Jos malli on säännöllinen, niin

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemäärän ominaisuuksia

- Käytetään merkintöjä $s_n(\theta; \mathbf{y}_n) = \partial l_n(\theta; \mathbf{y}_n) / \partial \theta$ ja $\mathcal{I}_n(\theta)$.
- **Lause 2.1.** Jos malli on säännöllinen, niin
 - (i) $E_\theta [s_n(\theta; \mathbf{Y}_n)] = 0$ kaikilla $n \geq 1$ ja

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemäärän ominaisuuksia

- Käytetään merkintöjä $s_n(\theta; \mathbf{y}_n) = \partial l_n(\theta; \mathbf{y}_n) / \partial \theta$ ja $\mathcal{I}_n(\theta)$.
- **Lause 2.1.** Jos malli on säännöllinen, niin
 - (i) $E_\theta [s_n(\theta; \mathbf{Y}_n)] = 0$ kaikilla $n \geq 1$ ja
 - (ii) $E_\theta [s_n(\theta; \mathbf{Y}_n) | \mathbf{Y}_{n-1}] = s_{n-1}(\theta; \mathbf{Y}_{n-1})$ kaikilla $n \geq 2$, ja

Uskottavuuspäätelyä

Uskottavuusfunktio ja SU-estimaattori: Pistemäärän ominaisuuksia

- Käytetään merkintöjä $s_n(\theta; \mathbf{y}_n) = \partial l_n(\theta; \mathbf{y}_n) / \partial \theta$ ja $\mathcal{I}_n(\theta)$.
- **Lause 2.1.** Jos malli on säännöllinen, niin
 - (i) $E_\theta [s_n(\theta; \mathbf{Y}_n)] = 0$ kaikilla $n \geq 1$ ja
 - (ii) $E_\theta [s_n(\theta; \mathbf{Y}_n) | \mathbf{Y}_{n-1}] = s_{n-1}(\theta; \mathbf{Y}_{n-1})$ kaikilla $n \geq 2$, ja
 - (iii) $\text{Cov}_\theta [s_n(\theta; \mathbf{Y}_n)] = \mathcal{I}_n(\theta)$.

- Käytetään merkintöjä $s_n(\theta; \mathbf{y}_n) = \partial l_n(\theta; \mathbf{y}_n) / \partial \theta$ ja $\mathcal{I}_n(\theta)$.
- **Lause 2.1.** Jos malli on säännöllinen, niin
 - (i) $E_\theta [s_n(\theta; \mathbf{Y}_n)] = 0$ kaikilla $n \geq 1$ ja
 - (ii) $E_\theta [s_n(\theta; \mathbf{Y}_n) | \mathbf{Y}_{n-1}] = s_{n-1}(\theta; \mathbf{Y}_{n-1})$ kaikilla $n \geq 2$, ja
 - (iii) $\text{Cov}_\theta [s_n(\theta; \mathbf{Y}_n)] = \mathcal{I}_n(\theta)$.
- (ii) ja (iii) \Rightarrow jono $s_n(\theta; \mathbf{Y}_n) = \sum_{i=1}^n u_i(\theta; Y_i)$ on martingaali ja $u_i(\theta; Y_i) = \partial \log f_{i-1}(Y_i; \theta) / \partial \theta$ on MD ($n = 1, 2, \dots$) informaatiojoukon $\mathbf{Y}_n = (Y_1, \dots, Y_n)$ suhteen.

- Tarkasteltaessa tarkentuvuutta yleisessä SU-kehikossa otettava käyttöön merkintä θ_0 "todelliselle" parametriarvolle.

- Tarkasteltaessa tarkentuvuutta yleisessä SU-kehikossa otettava käyttöön merkintä θ_0 "todelliselle" parametriarvolle.
- Ts., θ_0 on se parametriarvun Θ piste, joka vastaa aineiston tuottanutta todennäköisyysmekanismia.

- Tarkasteltaessa tarkentuvuutta yleisessä SU-kehikossa otettava käyttöön merkintä θ_0 "todelliselle" parametriarvolle.
- Ts., θ_0 on se parametriarvun Θ piste, joka vastaa aineiston tuottanutta todennäköisyysmekanismia.
- θ esiintyy mallissa $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta)$ "vapaana" muuttujana ja kuvaa mahdollisia vaihtoehtoisia parametriarvoja.

- Tarkasteltaessa tarkentuvuutta yleisessä SU-kehikossa otettava käyttöön merkintä θ_0 "todelliselle" parametriarvolle.
- Ts., θ_0 on se parametriavaruuden Θ piste, joka vastaa aineiston tuottanutta todennäköisyysmekanismia.
- θ esiintyy mallissa $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta)$ "vapaana" muuttujana ja kuvaa mahdollisia vaihtoehtoisia parametriarvoja.
- Aineistoa vastaavan sv:n \mathbf{Y}_n oletetaan noudattavan mallia $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta_0)$, johon kaikki todennäköisyyspäätelmät perustuvat.

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Parametrin β SU-estimaattori on PNS-estimaattori

$$\hat{\beta} = \left(\sum_{i=1}^n Z_i Z_i' \right)^{-1} \sum_{i=1}^n Z_i Y_i,$$

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Parametrin β SU-estimaattori on PNS-estimaattori

$$\hat{\beta} = \left(\sum_{i=1}^n Z_i Z_i' \right)^{-1} \sum_{i=1}^n Z_i Y_i,$$

- joka voidaan kirjoittaa (tässä β on todellinen parametriarvo)

$$\hat{\beta} = \left(\sum_{i=1}^n Z_i Z_i' \right)^{-1} \sum_{i=1}^n Z_i Y_i = \beta + \left(\frac{1}{n} \sum_{i=1}^n Z_i Z_i' \right)^{-1} \frac{1}{n} \sum_{i=1}^n Z_i \varepsilon_i.$$

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Oletetaan

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Oletetaan
 - $\frac{1}{n} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Oletetaan

- $\frac{1}{n} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti
- $\frac{1}{n} \sum_{i=1}^n Z_i \varepsilon_i \xrightarrow{P} 0$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Oletetaan
 - $\frac{1}{n} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti
 - $\frac{1}{n} \sum_{i=1}^n Z_i \varepsilon_i \xrightarrow{P} 0$.
- Nämä pätevät, kun $\{Z_i\}_{i=1}^{\infty}$ on esimerkiksi iid tai yleisemmin m -riippuva ja $E(Z_{a,i}^4) \leq C < \infty$ kaikilla a ja i .

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Oletetaan
 - $\frac{1}{n} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti
 - $\frac{1}{n} \sum_{i=1}^n Z_i \varepsilon_i \xrightarrow{P} 0$.
- Nämä pätevät, kun $\{Z_i\}_{i=1}^{\infty}$ on esimerkiksi iid tai yleisemmin m -riippuva ja $E(Z_{a,i}^4) \leq C < \infty$ kaikilla a ja i .
- Tällöin,

$\hat{\beta}$ on tarkentuva eli $\hat{\beta} \xrightarrow{P} \beta$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: PNS-estimaattori

- Oletetaan
 - $\frac{1}{n} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti
 - $\frac{1}{n} \sum_{i=1}^n Z_i \varepsilon_i \xrightarrow{P} 0$.

- Nämä pätevät, kun $\{Z_i\}_{i=1}^{\infty}$ on esimerkiksi iid tai yleisemmin m -riippuva ja $E(Z_{a,i}^4) \leq C < \infty$ kaikilla a ja i .

- Tällöin,

$\hat{\beta}$ on tarkentuva eli $\hat{\beta} \xrightarrow{P} \beta$.

- Ei vaadi normaalisuusoletusta, joten riittää, että $\{\varepsilon_i\}_{i=1}^{\infty}$ iid-jono, jolla $E(\varepsilon_i) = 0$ ja $E(\varepsilon_i^2) = \sigma^2 < \infty$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1} l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1} l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
- Tulkitaan $\bar{l}(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n E[\log f_{i-1}(Y_i; \theta)]$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
- Tulkitaan $\bar{l}(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n E[\log f_{i-1}(Y_i; \theta)]$.
 - Ts., "suurilla" havaintomäärillä ja todennäköisyydellä, joka on lähes yksi, $n^{-1}l_n(\theta; \mathbf{Y}_n)$ on "lähellä" rajafunktiota $\bar{l}(\theta)$ eikä "läheisyys" riipu siitä mikä parametriarvo on kysymyksessä.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
- Tulkitaan $\bar{l}(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n E[\log f_{i-1}(Y_i; \theta)]$.
 - Ts., "suurilla" havaintomäärillä ja todennäköisyydellä, joka on lähes yksi, $n^{-1}l_n(\theta; \mathbf{Y}_n)$ on "lähellä" rajafunktiota $\bar{l}(\theta)$ eikä "läheisyys" riipu siitä mikä parametriarvo on kysymyksessä.
 - Tällöin intuitiivisesti $n^{-1}l_n(\theta; \mathbf{Y}_n)$:n maksimipiste $\hat{\theta}_n$ konvergoi stokastisesti kohti $\bar{l}(\theta)$:n yhtä ainoaa maksimipistettä, jos sellainen on.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- (i) $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
- Tällöin intuitiivisesti $n^{-1}l_n(\theta; \mathbf{Y}_n)$:n maksimipiste $\hat{\theta}_n$ konvergoi stokastisesti kohti $\bar{l}(\theta)$:n yhtä ainoaa maksimipistettä, jos sellainen on.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
- Tällöin intuitiivisesti $n^{-1}l_n(\theta; \mathbf{Y}_n)$:n maksimipiste $\hat{\theta}_n$ konvergoi stokastisesti kohti $\bar{l}(\theta)$:n yhtä ainoaa maksimipistettä, jos sellainen on.
- **(ii)** Asetetaan ehto, joka takaa, että rajafunktiolla on yksikäsitteinen maksimi todellisessa parametriarvossa θ_0 .

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Kaksi yleisluonteista riittävää ehtoa SUE:n $\hat{\theta}_n$ tarkentuvuudelle ($f_0(y_1; \theta) = f_{Y_1}(y_1; \theta)$).
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
- Tällöin intuitiivisesti $n^{-1}l_n(\theta; \mathbf{Y}_n)$:n maksimipiste $\hat{\theta}_n$ konvergoi stokastisesti kohti $\bar{l}(\theta)$:n yhtä ainoaa maksimipistettä, jos sellainen on.
- **(ii)** Asetetaan ehto, joka takaa, että rajafunktiolla on yksikäsitteinen maksimi todellisessa parametriarvossa θ_0 .
- Tällöin tarkentuvuus seuraa.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

Lause 2.2. Olkoon $\bar{l} : \Theta \rightarrow \mathbb{R}$ ei-satunnainen funktio. Oletetaan, että

- (i) $\frac{1}{n} l_n(\theta; \mathbf{Y}_n) \xrightarrow{p} \bar{l}(\theta)$ tasaisesti joukossa Θ ja

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

Lause 2.2. Olkoon $\bar{l} : \Theta \rightarrow \mathbb{R}$ ei-satunnainen funktio. Oletetaan, että

- (i) $\frac{1}{n} l_n(\theta; \mathbf{Y}_n) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti joukossa Θ ja
- (ii) jokaisella $\varepsilon > 0$, $\sup_{\|\theta - \theta_0\| \geq \varepsilon} \bar{l}(\theta) < \bar{l}(\theta_0)$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

Lause 2.2. Olkoon $\bar{l} : \Theta \rightarrow \mathbb{R}$ ei-satunnainen funktio. Oletetaan, että

- (i) $\frac{1}{n} l_n(\theta; \mathbf{Y}_n) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti joukossa Θ ja
- (ii) jokaisella $\varepsilon > 0$, $\sup_{\|\theta - \theta_0\| \geq \varepsilon} \bar{l}(\theta) < \bar{l}(\theta_0)$.
- Tällöin SU-estimaattori on tarkentuva eli $\hat{\theta}_n \xrightarrow{P} \theta_0$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

Lause 2.2. Olkoon $\bar{l} : \Theta \rightarrow \mathbb{R}$ ei-satunnainen funktio. Oletetaan, että

- (i) $\frac{1}{n} l_n(\theta; \mathbf{Y}_n) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti joukossa Θ ja
- (ii) jokaisella $\varepsilon > 0$, $\sup_{\|\theta - \theta_0\| \geq \varepsilon} \bar{l}(\theta) < \bar{l}(\theta_0)$.
- Tällöin SU-estimaattori on tarkentuva eli $\hat{\theta}_n \xrightarrow{P} \theta_0$.
- Huom.: Mallin säännöllisyyttä ei vaadita.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.
- (i) $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
 - Todetaan konkreettisisä tilanteissa soveltamalla jotain useista tasaisista SLL:sta – ei välttämättä yksinkertaista.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.
- (i) $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
 - Todetaan konkreettisisissa tilanteissa soveltamalla jotain useista tasaisista SLL:sta – ei välttämättä yksinkertaista.
 - Toisaalta tasaisia SLL:ja on esitetty usein erilaisin oletuksin sallien havaintojen riippuvuus ja jakaumien heterogeenisuus.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
 - Todetaan konkreettisisä tilanteissa soveltamalla jotain useista tasaisista SLL:sta – ei välttämättä yksinkertaista.
 - Toisaalta tasaisia SLL:ja on esitetty usein erilaisin oletuksin sallien havaintojen riippuvuus ja jakaumien heterogeenisuus.
- **(ii)** jokaisella $\varepsilon > 0$, $\sup_{\|\theta - \theta_0\| \geq \varepsilon} \bar{l}(\theta) < \bar{l}(\theta_0)$.

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
 - Todetaan konkreettisisissa tilanteissa soveltamalla jotain useista tasaisista SLL:sta – ei välttämättä yksinkertaista.
 - Toisaalta tasaisia SLL:ja on esitetty usein erilaisin oletuksin sallien havaintojen riippuvuus ja jakaumien heterogeenisuus.
- **(ii)** jokaisella $\varepsilon > 0$, $\sup_{\|\theta - \theta_0\| \geq \varepsilon} \bar{l}(\theta) < \bar{l}(\theta_0)$.
 - Takaa, että funktiolla \bar{l} on yksikäsitteinen maksimi pisteessä θ_0 .

SU-estimaattorin asymptotiikka

Tarkentuvuus: Yleinen tapaus

- Oletusten yleisluonteisuuden vuoksi tarkentuvuustuloksen merkitys on pitkälti periaatteellinen.
- **(i)** $n^{-1}l_n(\theta; \mathbf{Y}_n) = n^{-1} \sum_{i=1}^n \log f_{i-1}(Y_i; \theta) \xrightarrow{P} \bar{l}(\theta)$ tasaisesti Θ :ssa.
 - Todetaan konkreettisisissa tilanteissa soveltamalla jotain useista tasaisista SLL:sta – ei välttämättä yksinkertaista.
 - Toisaalta tasaisia SLL:ja on esitetty usein erilaisin oletuksin sallien havaintojen riippuvuus ja jakaumien heterogeenisuus.
- **(ii)** jokaisella $\varepsilon > 0$, $\sup_{\|\theta - \theta_0\| \geq \varepsilon} \bar{l}(\theta) < \bar{l}(\theta_0)$.
 - Takaa, että funktiolla \bar{l} on yksikäsitteinen maksimi pisteessä θ_0 .
 - Voidaan tulkita parametria θ koskevaksi identifiointiehdoksi.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus

- Kun SU-estimaattorin tarkentuvuus on todettu, voidaan asymptoottinen normalisuus osoittaa käyttäen pistemäärän Taylorin kehitelmää tai väliarvolauseetta.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus

- Kun SU-estimaattorin tarkentuvuus on todettu, voidaan asymptoottinen normalisuus osoittaa käyttäen pistemäärän Taylorin kehitelmää tai väliarvolausetta.
- Tämä vaatii uskottavuusfunktion toisten derivaattojen olemassaolon, joka seuraa mallin oletetusta säännöllisyydestä (jakso 2.3).

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus

- Kun SU-estimaattorin tarkentuvuus on todettu, voidaan asymptoottinen normalisuus osoittaa käyttäen pistemäärän Taylorin kehitelmää tai väliarvolauseetta.
- Tämä vaatii uskottavuusfunktion toisten derivaattojen olemassaolon, joka seuraa mallin oletetusta säännöllisyydestä (jakso 2.3).
- Keskeinen elementti SU-estimaattorin asymptoottisen normalisuuden osoittamisessa on säännöllisyydestä seuraava pistemäärän martingaaliominaisuus (ks. Lause 2.1), joka sopivin lisäehdoin mahdollistaa martingaalien KRL:een soveltamisen (ks. Lause 1.6).

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus

- Kun SU-estimaattorin tarkentuvuus on todettu, voidaan asymptoottinen normalisuus osoittaa käyttäen pistemäärän Taylorin kehitelmää tai väliarvolauseetta.
- Tämä vaatii uskottavuusfunktion toisten derivaattojen olemassaolon, joka seuraa mallin oletetusta säännöllisyydestä (jakso 2.3).
- Keskeinen elementti SU-estimaattorin asymptoottisen normalisuuden osoittamisessa on säännöllisyydestä seuraava pistemäärän martingaaliominaisuus (ks. Lause 2.1), joka sopivin lisäehdoin mahdollistaa martingaalien KRL:een soveltamisen (ks. Lause 1.6).
- PNS-estimaattoria koskeva esimerkki havainnollistaa yleisessä tapauksessa vaadittavia tarkasteluja.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Malliyhtälöstä seuraa

$$\sqrt{n}(\hat{\beta} - \beta) = \left(n^{-1} \sum_{i=1}^n Z_i Z_i' \right)^{-1} n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i,$$

jossa oletetaan jälleen

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Malliyhtälöstä seuraa

$$\sqrt{n}(\hat{\beta} - \beta) = \left(n^{-1} \sum_{i=1}^n Z_i Z_i' \right)^{-1} n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i,$$

jossa oletetaan jälleen

- $n^{-1} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Malliyhtälöstä seuraa

$$\sqrt{n}(\hat{\beta} - \beta) = \left(n^{-1} \sum_{i=1}^n Z_i Z_i' \right)^{-1} n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i,$$

jossa oletetaan jälleen

- $n^{-1} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti
- Kun $E(|Z_{i,a}|) < \infty$, on $\{Z_i \varepsilon_i\}_{i=1}^{\infty}$ on MD-jono (ks. HT 3.1) ja voidaan olettaa (ks. lause 1.6)

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\|}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \underline{\underline{\|}} \varepsilon_i$ ja siten $Z_i \underline{\underline{\|}} \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Malliyhtälöstä seuraa

$$\sqrt{n}(\hat{\beta} - \beta) = \left(n^{-1} \sum_{i=1}^n Z_i Z_i' \right)^{-1} n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i,$$

jossa oletetaan jälleen

- $n^{-1} \sum_{i=1}^n Z_i Z_i' \xrightarrow{P} Q$, Q ei-satunnainen ja positiivisesti definiitti
- Kun $E(|Z_{i,a}|) < \infty$, on $\{Z_i \varepsilon_i\}_{i=1}^{\infty}$ on MD-jono (ks. HT 3.1) ja voidaan olettaa (ks. lause 1.6)
 - $n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i \xrightarrow{d} N(0, \sigma^2 Q)$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: PNS-estimaattori

- Tarkastellaan lineaarista mallia

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\parallel},$$

jossa $(\mathbf{W}_{i-1}, X_i) \underline{\parallel} \varepsilon_i$ ja siten $Z_i \underline{\parallel} \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Malliyhtälöstä seuraa

$$\sqrt{n}(\hat{\beta} - \beta) = \left(n^{-1} \sum_{i=1}^n Z_i Z_i' \right)^{-1} n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i,$$

jossa oletetaan jälleen

- $n^{-1} \sum_{i=1}^n Z_i Z_i' \xrightarrow{p} Q$, Q ei-satunnainen ja positiivisesti definiitti
- Kun $E(|Z_{i,a}|) < \infty$, on $\{Z_i \varepsilon_i\}_{i=1}^{\infty}$ on MD-jono (ks. HT 3.1) ja voidaan olettaa (ks. lause 1.6)
 - $n^{-1/2} \sum_{i=1}^n Z_i \varepsilon_i \xrightarrow{d} N(0, \sigma^2 Q)$
- Saadaan tulos

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} N(0, \sigma^2 Q^{-1})$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Aineistoa vastaava sv \mathbf{Y}_n noudattaa jälleen mallia $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta_0)$.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Aineistoa vastaava sv \mathbf{Y}_n noudattaa jälleen mallia $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta_0)$.
- Pistemäärä $s_n(\theta; \mathbf{y}_n)$, havaittu info $\mathcal{J}_n(\theta; \mathbf{y}_n)$, Fisherin info $\mathcal{I}_n(\theta)$:

$$s_n(\theta; \mathbf{y}_n) = \frac{\partial}{\partial \theta} l_n(\theta; \mathbf{y}_n) \quad (d \times 1)$$

$$s_{a,n}(\theta; \mathbf{y}_n) = \frac{\partial}{\partial \theta_a} l_n(\theta; \mathbf{y}_n) \quad (a = 1, \dots, d)$$

$$\frac{\partial}{\partial \theta'} s_{a,n}(\theta; \mathbf{y}_n) = \left[\frac{\partial}{\partial \theta_1} s_{a,n}(\theta; \mathbf{y}_n) \quad \dots \quad \frac{\partial}{\partial \theta_d} s_{a,n}(\theta; \mathbf{y}_n) \right] \quad (1 \times d)$$

$$\mathcal{I}_n(\theta) = E_{\theta} [\mathcal{J}_n(\theta; \mathbf{Y}_n)] = -E_{\theta} [\partial^2 l_n(\theta; \mathbf{Y}_n) / \partial \theta \theta']$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Aineistoa vastaava sv \mathbf{Y}_n noudattaa jälleen mallia $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta_0)$.
- Pistemäärä $s_n(\theta; \mathbf{y}_n)$, havaittu info $\mathcal{J}_n(\theta; \mathbf{y}_n)$, Fisherin info $\mathcal{I}_n(\theta)$:

$$s_n(\theta; \mathbf{y}_n) = \frac{\partial}{\partial \theta} l_n(\theta; \mathbf{y}_n) \quad (d \times 1)$$

$$s_{a,n}(\theta; \mathbf{y}_n) = \frac{\partial}{\partial \theta_a} l_n(\theta; \mathbf{y}_n) \quad (a = 1, \dots, d)$$

$$\frac{\partial}{\partial \theta'} s_{a,n}(\theta; \mathbf{y}_n) = \left[\frac{\partial}{\partial \theta_1} s_{a,n}(\theta; \mathbf{y}_n) \quad \dots \quad \frac{\partial}{\partial \theta_d} s_{a,n}(\theta; \mathbf{y}_n) \right] \quad (1 \times d)$$

$$\mathcal{I}_n(\theta) = E_{\theta} [\mathcal{J}_n(\theta; \mathbf{Y}_n)] = -E_{\theta} [\partial^2 l_n(\theta; \mathbf{Y}_n) / \partial \theta \theta']$$

- $\frac{\partial}{\partial \theta'} s_{a,n}(\theta; \mathbf{y}_n) =$ matriisin $\partial^2 l_n(\theta; \mathbf{y}_n) / \partial \theta \theta' = -\mathcal{J}_n(\theta; \mathbf{y}_n)$ a. rivi.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Aineistoa vastaava sv \mathbf{Y}_n noudattaa jälleen mallia $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta_0)$.
- Pistemäärä $s_n(\theta; \mathbf{y}_n)$, havaittu info $\mathcal{J}_n(\theta; \mathbf{y}_n)$, Fisherin info $\mathcal{I}_n(\theta)$:

$$s_n(\theta; \mathbf{y}_n) = \frac{\partial}{\partial \theta} l_n(\theta; \mathbf{y}_n) \quad (d \times 1)$$

$$s_{a,n}(\theta; \mathbf{y}_n) = \frac{\partial}{\partial \theta_a} l_n(\theta; \mathbf{y}_n) \quad (a = 1, \dots, d)$$

$$\frac{\partial}{\partial \theta'} s_{a,n}(\theta; \mathbf{y}_n) = \left[\frac{\partial}{\partial \theta_1} s_{a,n}(\theta; \mathbf{y}_n) \quad \cdots \quad \frac{\partial}{\partial \theta_d} s_{a,n}(\theta; \mathbf{y}_n) \right] \quad (1 \times d)$$

$$\mathcal{I}_n(\theta) = E_{\theta} [\mathcal{J}_n(\theta; \mathbf{Y}_n)] = -E_{\theta} [\partial^2 l_n(\theta; \mathbf{Y}_n) / \partial \theta \theta']$$

- $\frac{\partial}{\partial \theta'} s_{a,n}(\theta; \mathbf{y}_n) =$ matriisin $\partial^2 l_n(\theta; \mathbf{y}_n) / \partial \theta \theta' = -\mathcal{J}_n(\theta; \mathbf{y}_n)$ a . rivi.
- Parametriavaruuden $\Theta \subseteq \mathbb{R}^d$ oletetaan olevan avoin ja konvekksi, mikä takaa tarvittavan väliarvolauseen soveltamisen.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Usean muuttujan funktion väliarvolause \Rightarrow

$$s_{a,n}(\hat{\theta}_n; \mathbf{Y}_n) = s_{a,n}(\theta_0; \mathbf{Y}_n) + \frac{\partial}{\partial \theta'} s_{a,n}(\bar{\theta}_{a,n}; \mathbf{Y}_n) (\hat{\theta}_n - \theta_0), \quad a = 1, \dots, d,$$

jossa

$$\bar{\theta}_{a,n} = c_a \hat{\theta}_n + (1 - c_a) \theta_0, \quad 0 \leq c_a \leq 1, \quad a = 1, \dots, d.$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Usean muuttujan funktion väliarvolause \Rightarrow

$$s_{a,n}(\hat{\theta}_n; \mathbf{Y}_n) = s_{a,n}(\theta_0; \mathbf{Y}_n) + \frac{\partial}{\partial \theta'} s_{a,n}(\bar{\theta}_{a,n}; \mathbf{Y}_n) (\hat{\theta}_n - \theta_0), \quad a = 1, \dots, d,$$

jossa

$$\bar{\theta}_{a,n} = c_a \hat{\theta}_n + (1 - c_a) \theta_0, \quad 0 \leq c_a \leq 1, \quad a = 1, \dots, d.$$

- Väli pisteille $\bar{\theta}_{a,n}$ (jotka satunnaisia) pätee

$$\|\bar{\theta}_{a,n} - \theta_0\| \leq \|\hat{\theta}_n - \theta_0\|, \quad a = 1, \dots, d.$$

- Usean muuttujan funktion väliarvolause \Rightarrow

$$s_{a,n}(\hat{\theta}_n; \mathbf{Y}_n) = s_{a,n}(\theta_0; \mathbf{Y}_n) + \frac{\partial}{\partial \theta'} s_{a,n}(\bar{\theta}_{a,n}; \mathbf{Y}_n) (\hat{\theta}_n - \theta_0), \quad a = 1, \dots, d,$$

jossa

$$\bar{\theta}_{a,n} = c_a \hat{\theta}_n + (1 - c_a) \theta_0, \quad 0 \leq c_a \leq 1, \quad a = 1, \dots, d.$$

- Väli pisteille $\bar{\theta}_{a,n}$ (jotka satunnaisia) pätee

$$\|\bar{\theta}_{a,n} - \theta_0\| \leq \|\hat{\theta}_n - \theta_0\|, \quad a = 1, \dots, d.$$

- Oletus $\hat{\theta}_n \xrightarrow{P} \theta_0 \Rightarrow \bar{\theta}_{a,n} \xrightarrow{P} \theta_0$ (HT 1.1)

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$s_n(\hat{\theta}_n; \mathbf{Y}_n) = s_n(\theta_0; \mathbf{Y}_n) - \tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)(\hat{\theta}_n - \theta_0), \quad (*)$$

jossa

$$\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n) :n \text{ a. rivi} = \mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n) :n \text{ a. rivi}$$

eli matriisin $\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$ eri riveillä on eri välipisteet.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$s_n(\hat{\theta}_n; \mathbf{Y}_n) = s_n(\theta_0; \mathbf{Y}_n) - \tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)(\hat{\theta}_n - \theta_0), \quad (*)$$

jossa

$$\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n) :n \text{ a. rivi} = \mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n) :n \text{ a. rivi}$$

eli matriisiin $\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$ eri riveillä on eri välipisteet.

- SUE:n $\hat{\theta}_n$ oletettu olemassaolo $\Rightarrow s_n(\hat{\theta}_n; \mathbf{Y}_n) = 0$.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$s_n(\hat{\theta}_n; \mathbf{Y}_n) = s_n(\theta_0; \mathbf{Y}_n) - \tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)(\hat{\theta}_n - \theta_0), \quad (*)$$

jossa

$$\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n) : n \text{ a. rivi} = \mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n) : n \text{ a. rivi}$$

eli matriisiin $\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$ eri riveillä on eri välipisteet.

- SUE:n $\hat{\theta}_n$ oletettu olemassaolo $\Rightarrow s_n(\hat{\theta}_n; \mathbf{Y}_n) = 0$.
- Jos oletetaan $\tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$ epäsingulaariseksi, saadaan (*) :stä

$$\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n} \tilde{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n) \right)^{-1} \frac{1}{\sqrt{n}} s_n(\theta_0; \mathbf{Y}_n).$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- $$\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n} \bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n) \right)^{-1} \frac{1}{\sqrt{n}} s_n(\theta_0; \mathbf{Y}_n).$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- $\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n}\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)\right)^{-1} \frac{1}{\sqrt{n}}s_n(\theta_0; \mathbf{Y}_n).$
- $\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$:n a . rivi = $\mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n)$:n a . rivi

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- $\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n}\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)\right)^{-1} \frac{1}{\sqrt{n}}s_n(\theta_0; \mathbf{Y}_n)$.
- $\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$:n a . rivi = $\mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n)$:n a . rivi
- $\frac{1}{n}\mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n) = -\frac{1}{n}\sum_{i=1}^n \frac{\partial^2}{\partial\theta\partial\theta'} \log f_{i-1}(Y_i; \bar{\theta}_{a,n})$ on otoskeskiarvo, johon tavoitteena soveltaa SLL:ia.

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus

- $\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n}\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)\right)^{-1} \frac{1}{\sqrt{n}}s_n(\theta_0; \mathbf{Y}_n).$
- $\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)$:n a . rivi = $\mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n)$:n a . rivi
- $\frac{1}{n}\mathcal{J}_n(\bar{\theta}_{a,n}; \mathbf{Y}_n) = -\frac{1}{n}\sum_{i=1}^n \frac{\partial^2}{\partial\theta\partial\theta'} \log f_{i-1}(Y_i; \bar{\theta}_{a,n})$ on otoskeskiarvo, johon tavoitteena soveltaa SLL:ia.
- Koska argumentti $\bar{\theta}_{a,n}$ on satunnainen, tarvitaan skaalatulle havaitulle informaatiomatriisille $\frac{1}{n}\mathcal{J}_n(\theta; \mathbf{Y}_n)$ tasainen SLL (vrt. Lause 1.5).

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Oletetaan

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

jossa

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(\mathbf{Y}_i; \theta) \right] \\ &= \lim_{n \rightarrow \infty} \frac{1}{n} \mathbb{E} [\mathcal{J}_n(\theta; \mathbf{Y}_n)] = \bar{\mathcal{I}}(\theta), \quad \theta \in \Theta, \end{aligned}$$

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus

- Oletetaan

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

jossa

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(\mathbf{Y}_i; \theta) \right] \\ &= \lim_{n \rightarrow \infty} \frac{1}{n} \mathbb{E} [\mathcal{J}_n(\theta; \mathbf{Y}_n)] = \bar{\mathcal{I}}(\theta), \quad \theta \in \Theta, \end{aligned}$$

- ja raja-arvon olemassaolo oletetaan.

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus

- Oletetaan

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

jossa

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(\mathbf{Y}_i; \theta) \right] \\ &= \lim_{n \rightarrow \infty} \frac{1}{n} \mathbb{E} [\mathcal{J}_n(\theta; \mathbf{Y}_n)] = \bar{\mathcal{I}}(\theta), \quad \theta \in \Theta, \end{aligned}$$

- ja raja-arvon olemassaolo oletetaan.
- Samoin $\bar{\mathcal{I}}(\theta)$:n jatkossa tarvittava jatkuvuus ja positiivisdefiniittisyys (ja siten epäsingulaarisuus) pisteessä θ_0 .

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- $\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n}\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)\right)^{-1} \frac{1}{\sqrt{n}}s_n(\theta_0; \mathbf{Y}_n).$

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus

- $\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n}\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)\right)^{-1} \frac{1}{\sqrt{n}}s_n(\theta_0; \mathbf{Y}_n)$.
- $s_n(\theta_0; \mathbf{Y}_n) = \sum_{i=1}^n u_i(\theta_0; \mathbf{Y}_i)$ on martingaali (Lause 2.1) ja (ks. (2.23))

$$\text{Cov}_{\theta_0} \left[n^{-1/2} s_n(\theta_0; \mathbf{Y}_n) \right] = n^{-1} \mathcal{I}_n(\theta_0) = n^{-1} \times \text{Fisherin info}(\theta_0)$$

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus

- $\sqrt{n}(\hat{\theta}_n - \theta_0) = \left(\frac{1}{n}\bar{\mathcal{J}}_n(\bar{\theta}_n; \mathbf{Y}_n)\right)^{-1} \frac{1}{\sqrt{n}}s_n(\theta_0; \mathbf{Y}_n)$.
- $s_n(\theta_0; \mathbf{Y}_n) = \sum_{i=1}^n u_i(\theta_0; \mathbf{Y}_i)$ on martingaali (Lause 2.1) ja (ks. (2.23))

$$\text{Cov}_{\theta_0} \left[n^{-1/2} s_n(\theta_0; \mathbf{Y}_n) \right] = n^{-1} \mathcal{I}_n(\theta_0) = n^{-1} \times \text{Fisherin info}(\theta_0)$$

- Kun MD-jonon $u_i(\theta_0; \mathbf{Y}_i)$, $i \geq 1$, oletetaan toteuttavan Lauseen 1.6 ehdot (i) ja (ii), saadaan

$$\frac{1}{\sqrt{n}} s_n(\theta_0; \mathbf{Y}_n) \xrightarrow{d} \text{N}(0, \bar{\mathcal{I}}(\theta_0)), \quad \bar{\mathcal{I}}(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta).$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Oletukset

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta, \quad (2.30)$$

$$\lim_{n \rightarrow \infty} \frac{1}{n} \mathbb{E}[\mathcal{J}_n(\theta; \mathbf{Y}_n)] = \bar{\mathcal{I}}(\theta), \quad \theta \in \Theta. \quad (2.31)$$

$$\frac{1}{\sqrt{n}} s_n(\theta_0; \mathbf{Y}_n) \xrightarrow{d} \mathbb{N}(0, \bar{\mathcal{I}}(\theta_0)) \quad (2.32)$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Oletukset

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta, \quad (2.30)$$

$$\lim_{n \rightarrow \infty} \frac{1}{n} \mathbb{E}[\mathcal{J}_n(\theta; \mathbf{Y}_n)] = \bar{\mathcal{I}}(\theta), \quad \theta \in \Theta. \quad (2.31)$$

$$\frac{1}{\sqrt{n}} s_n(\theta_0; \mathbf{Y}_n) \xrightarrow{d} \mathcal{N}(0, \bar{\mathcal{I}}(\theta_0)) \quad (2.32)$$

- Lause 2.3.** Olkoon $f_{\mathbf{Y}_n}(\mathbf{y}_n; \theta)$, $\theta \in \Theta$, säännöllinen ja Θ avoin ja konvekksi. Oletetaan, (2.30), (2.31) ja (2.32) ja että $\bar{\mathcal{I}}(\theta)$ on positiivisesti definiitti ja jatkuva pisteessä θ_0 . Jos SU-estimaattori $\hat{\theta}_n$ on lisäksi tarkentuva, niin

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathcal{N}\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{P} \bar{\mathcal{I}}(\theta_0).$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}\left(0, \tilde{\mathcal{I}}(\theta_0)^{-1}\right)$$



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right)$$

- iid-tapauksessa

$$\begin{aligned}\bar{\mathcal{I}}(\theta_0) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(Y_i; \theta) \right] \\ &= \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{Y_1}(Y_1; \theta) \right]\end{aligned}$$

on yksittäisen havainnon Fisherin informaatio.

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}\left(0, \tilde{\mathcal{I}}(\theta_0)^{-1}\right)$$

- iid-tapauksessa

$$\begin{aligned}\tilde{\mathcal{I}}(\theta_0) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(Y_i; \theta) \right] \\ &= \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{Y_1}(Y_1; \theta) \right]\end{aligned}$$

on yksittäisen havainnon Fisherin informaatio.

- Yleisesti, $\tilde{\mathcal{I}}(\theta_0)$ on "keskimääräinen" Fisherin informaatioksi.

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}\left(0, \tilde{\mathcal{I}}(\theta_0)^{-1}\right)$$

- iid-tapauksessa

$$\begin{aligned}\tilde{\mathcal{I}}(\theta_0) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{i-1}(Y_i; \theta) \right] \\ &= \mathbb{E} \left[-\frac{\partial^2}{\partial \theta \partial \theta'} \log f_{Y_1}(Y_1; \theta) \right]\end{aligned}$$

on yksittäisen havainnon Fisherin informaatio.

- Yleisesti, $\tilde{\mathcal{I}}(\theta_0)$ on "keskimääräinen" Fisherin informaatioksi.
- Lauseen 2.3 tulos osoittaa SU-estimaattorin asymptoottisen täystehokkuuden.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

- As. jakauman kovarianssimatriisin $\bar{\mathcal{I}}(\theta_0)^{-1}$ tarkentuva estimaattori saadaan kääntämällä skaalattu havaittu informaatiomatriisi $n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n)$.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus



$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

- As. jakauman kovarianssimatriisin $\bar{\mathcal{I}}(\theta_0)^{-1}$ tarkentuva estimaattori saadaan kääntämällä skaalattu havaittu informaatiomatriisi $n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n)$.
- Tätä tulosta voidaan käyttää SU-estimaattorin $\hat{\theta}_n$ komponenttien keskivirheiden laskemisessa tavanomaiseen tapaan.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Lauseen 2.3 merkitys on oletusten yleisluonteisuuden vuoksi pitkälti periaatteellinen.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Lauseen 2.3 merkitys on oletusten yleisluonteisuuden vuoksi pitkälti periaatteellinen.
- Konkreettisissa tilanteissa oletetut konvergenssit täytyy tarkistaa käyttäen tarkasteltavan mallin erityispiirteitä ja oletuksia.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Lauseen 2.3 merkitys on oletusten yleisluonteisuuden vuoksi pitkälti periaatteellinen.
- Konkreettisissa tilanteissa oletetut konvergenssit täytyy tarkistaa käyttäen tarkasteltavan mallin erityispiirteitä ja oletuksia.
- Yleensä hankalin on tarkistaa tasaista SLL:ia koskeva konvergenssi

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta.$$

SU-estimaattorin asymptotiikka

Asymptoottinen normaalisuus: Yleinen tapaus

- Lauseen 2.3 merkitys on oletusten yleisluonteisuuden vuoksi pitkälti periaatteellinen.
- Konkreettisissa tilanteissa oletetut konvergenssit täytyy tarkistaa käyttäen tarkasteltavan mallin erityispiirteitä ja oletuksia.
- Yleensä hankalin on tarkistaa tasaista SLL:ia koskeva konvergenssi

$$\frac{1}{n} \mathcal{J}_n(\theta; \mathbf{Y}_n) \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta.$$

- Teknisiä yksityiskohtia olennaisempaa on kuitenkin ymmärtää SU-estimaattorin asymptoottisen normaalisuuden todistamisessa käytettävät perusideat niiden toimiminen tapauksissa, joissa havainnot eivät ole riippumattomia ja samoin jakautuneita.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Parametriavaruuden avoimuutta ja konveksisuutta ei välttämättä tarvita, mutta käytetty väliarvolause vaatii, että todellinen parametriarvo θ_0 on parametriavaruuden sisäpiste.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Parametriavaruuden avoimuutta ja konveksisuutta ei välttämättä tarvita, mutta käytetty väliarvolause vaatii, että todellinen parametriarvo θ_0 on parametriavaruuden sisäpiste.
- Ei aina aivan harmiton oletus. Esimerkiksi malli

$$Y_j = \alpha_j \mathbf{1}_{n_j} + \gamma x_j + \varepsilon_j, \quad j = 1, \dots, N,$$

jossa

$$\begin{aligned} \varepsilon_1, \dots, \varepsilon_N &\stackrel{\text{iid}}{\parallel}, \quad \varepsilon_j \sim \mathbf{N}(0, \sigma^2 I_{n_j}), \\ \alpha_1, \dots, \alpha_N &\sim \mathbf{N}(\alpha, \omega^2) \stackrel{\text{iid}}{\parallel}, \quad \omega^2 \geq 0 \\ (\varepsilon_1, \dots, \varepsilon_N) &\stackrel{\text{iid}}{\parallel} (\alpha_1, \dots, \alpha_N). \end{aligned}$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Yleinen tapaus

- Parametriavaruuden avoimuutta ja konveksisuutta ei välttämättä tarvita, mutta käytetty väliarvolause vaatii, että todellinen parametriarvo θ_0 on parametriavaruuden sisäpiste.
- Ei aina aivan harmiton oletus. Esimerkiksi malli

$$Y_j = \alpha_j \mathbf{1}_{n_j} + \gamma x_j + \varepsilon_j, \quad j = 1, \dots, N,$$

jossa

$$\begin{aligned} \varepsilon_1, \dots, \varepsilon_N &\stackrel{\text{iid}}{\sim} \mathbf{N}(0, \sigma^2 I_{n_j}), \\ \alpha_1, \dots, \alpha_N &\sim \mathbf{N}(\alpha, \omega^2) \stackrel{\text{iid}}{\sim}, \quad \omega^2 \geq 0 \\ (\varepsilon_1, \dots, \varepsilon_N) &\stackrel{\text{iid}}{\sim} (\alpha_1, \dots, \alpha_N). \end{aligned}$$

- Hypoteesi $\omega^2 = 0$ usein kiinnostava.

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Ortogonaalisten parametrien tapaus

- Lauseen 2.3. oletuksiin pätee

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

Oletuksiin kuului

$$\lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \times \text{Fisherin info}(\theta) = \bar{\mathcal{I}}(\theta).$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Ortogonaalisten parametrien tapaus

- Lauseen 2.3. oletuksien pätee

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

Oletuksiin kuului

$$\lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \times \text{Fisherin info}(\theta) = \bar{\mathcal{I}}(\theta).$$

- Jos $\theta = (\psi, \lambda)$ ja ψ ja λ ovat ortogonaalisia, on $\mathcal{I}_n(\theta)$ lohki diagonaalinen ja siten

$$\bar{\mathcal{I}}(\theta) = \begin{bmatrix} \bar{\mathcal{I}}_{\psi\psi}(\theta) & 0 \\ 0 & \bar{\mathcal{I}}_{\lambda\lambda}(\theta) \end{bmatrix}.$$

SU-estimaattorin asymptotiikka

Asymptoottinen normalisuus: Ortogonaalisten parametrien tapaus

- Lauseen 2.3. oletuksien pätee

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

Oletuksiin kuului

$$\lim_{n \rightarrow \infty} \frac{1}{n} \mathcal{I}_n(\theta) = \lim_{n \rightarrow \infty} \frac{1}{n} \times \text{Fisherin info}(\theta) = \bar{\mathcal{I}}(\theta).$$

- Jos $\theta = (\psi, \lambda)$ ja ψ ja λ ovat ortogonaalisia, on $\mathcal{I}_n(\theta)$ lohki diagonaalinen ja siten

$$\bar{\mathcal{I}}(\theta) = \begin{bmatrix} \bar{\mathcal{I}}_{\psi\psi}(\theta) & 0 \\ 0 & \bar{\mathcal{I}}_{\lambda\lambda}(\theta) \end{bmatrix}.$$

- Tällöin SU-estimaattorit $\hat{\psi}_n$ ja $\hat{\lambda}_n$ ovat asymptoottisesti riippumattomia ja esimerkiksi

$$\sqrt{n}(\hat{\psi}_n - \psi_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}_{\psi\psi}(\theta_0)^{-1}\right).$$

- Tarkastellaan (todelliseen parametriarvoon) liitettyä lineaarista nollahypoteesia

$$H_0 : A\theta_0 = c,$$

jossa matriisi A ($q \times d$) ja vektori c ($q \times 1$) ovat tunnettuja ja A :n aste on q eli $r(A) = q$.

- Tarkastellaan (todelliseen parametriarvoon) liitettyä lineaarista nollahypoteesia

$$H_0 : A\theta_0 = c,$$

jossa matriisi A ($q \times d$) ja vektori c ($q \times 1$) ovat tunnettuja ja A :n aste on q eli $r(A) = q$.

- Vaihtoehtoinen hypoteesi on $A\theta_0 \neq c$.

- Tarkastellaan (todelliseen parametriarvoon) liitettyä lineaarista nollahypoteesia

$$H_0 : A\theta_0 = c,$$

jossa matriisi A ($q \times d$) ja vektori c ($q \times 1$) ovat tunnettuja ja A :n aste on q eli $r(A) = q$.

- Vaihtoehtoinen hypoteesi on $A\theta_0 \neq c$.
- Esimerkiksi,

$$A = [I_q : 0],$$

jolloin $H_0 \Rightarrow \theta_0$:n q ensimmäistä komponenttia = tunnettu c .

Uskottavuusfunktioon perustuvia testejä

Waldin testi

- Waldin testi perustuu SU-estimaattoriin $\hat{\theta}$ ja Lauseen 2.3 tulokseen

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathbf{N}\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

Uskottavuusfunktioon perustuvia testejä

Waldin testi

- Waldin testi perustuu SU-estimaattoriin $\hat{\theta}$ ja Lauseen 2.3 tulokseen

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

- Testisuure perustuu erotukseen

$$A\hat{\theta} - c,$$

joka saa tyypillisesti ”pieniä” arvoja, kun nollahypoteesi $A\theta_0 = c$ on tosi ja ”suuria” arvoja, kun nollahypoteesi ei ole tosi.

Uskottavuusfunktioon perustuvia testejä

Waldin testi

- Waldin testi perustuu SU-estimaattoriin $\hat{\theta}$ ja Lauseen 2.3 tulokseen

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

- Testisuure perustuu erotukseen

$$A\hat{\theta} - c,$$

joka saa tyypillisesti "pieniä" arvoja, kun nollahypoteesi $A\theta_0 = c$ on tosi ja "suuria" arvoja, kun nollahypoteesi ei ole tosi.

- Testisuure

$$W = \sqrt{n}(A\hat{\theta} - c)' \left[A (n^{-1} \mathcal{J}(\hat{\theta}; \mathbf{Y}))^{-1} A' \right]^{-1} \sqrt{n}(A\hat{\theta} - c) \xrightarrow{H_0} \chi_q^2.$$

Uskottavuusfunktioon perustuvia testejä

Waldin testi

- Waldin testi perustuu SU-estimaattoriin $\hat{\theta}$ ja Lauseen 2.3 tulokseen

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N\left(0, \bar{\mathcal{I}}(\theta_0)^{-1}\right) \quad \text{ja} \quad n^{-1} \mathcal{J}_n(\hat{\theta}_n; \mathbf{Y}_n) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0).$$

- Testisuure perustuu erotukseen

$$A\hat{\theta} - c,$$

joka saa tyypillisesti "pieniä" arvoja, kun nollahypoteesi $A\theta_0 = c$ on tosi ja "suuria" arvoja, kun nollahypoteesi ei ole tosi.

- Testisuure

$$W = \sqrt{n}(A\hat{\theta} - c)' \left[A (n^{-1} \mathcal{J}(\hat{\theta}; \mathbf{Y}))^{-1} A' \right]^{-1} \sqrt{n}(A\hat{\theta} - c) \xrightarrow{H_0} \chi_q^2.$$

- Approksimatiivinen P-arvo

$$P = P_{H_0} \{W \geq W(\mathbf{y})\} \approx P \{ \chi_q^2 \geq W(\mathbf{y}) \}.$$

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Waldin testi asymptoottisesti pätevä käytetäänpä mitä tahansa matriisin $\bar{\mathcal{I}}(\theta_0)$ tarkentuvaa estimaattoria.

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Waldin testi asympotoottisesti pätevä käytetäänpä mitä tahansa matriisiin $\tilde{\mathcal{I}}(\theta_0)$ tarkentuvaa estimaattoria.
- $s_n(\theta_0; \mathbf{Y}_n) = \sum_{i=1}^n u_i(\theta_0; Y_i)$, jossa $u_i(\theta_0; Y_i)$, $i \geq 1$, on MD-jono ja siten korreloimaton, joten oletuksen (2.31) perusteella,

$$\begin{aligned} \frac{1}{n} \mathbb{E} [s(\theta_0; \mathbf{Y}_n) s(\theta_0; \mathbf{Y}_n)'] &= \frac{1}{n} \sum_{i=1}^n \mathbb{E} [u_i(\theta_0; Y_i) u_i(\theta_0; Y_i)'] \\ &= \frac{1}{n} \mathcal{I}_n(\theta_0) \xrightarrow{n \rightarrow \infty} \tilde{\mathcal{I}}(\theta_0), \end{aligned}$$

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Waldin testi asympotoottisesti pätevä käytetäänpä mitä tahansa matriisiin $\bar{\mathcal{I}}(\theta_0)$ tarkentuvaa estimaattoria.
- $s_n(\theta_0; \mathbf{Y}_n) = \sum_{i=1}^n u_i(\theta_0; Y_i)$, jossa $u_i(\theta_0; Y_i)$, $i \geq 1$, on MD-jono ja siten korreloimaton, joten oletuksen (2.31) perusteella,

$$\begin{aligned}\frac{1}{n} \mathbb{E} [s(\theta_0; \mathbf{Y}_n) s(\theta_0; \mathbf{Y}_n)'] &= \frac{1}{n} \sum_{i=1}^n \mathbb{E} [u_i(\theta_0; Y_i) u_i(\theta_0; Y_i)'] \\ &= \frac{1}{n} \mathcal{I}_n(\theta_0) \xrightarrow{n \rightarrow \infty} \bar{\mathcal{I}}(\theta_0),\end{aligned}$$

- Siis, $\bar{\mathcal{I}}(\theta_0)$:n estimointi on luonteva perustaa myös ns. ulkotulomatriisiin

$$M_n(\hat{\theta}; \mathbf{Y}) = \sum_{i=1}^n u_i(\hat{\theta}; Y_i) u_i(\hat{\theta}; Y_i)'$$

Uskottavuusfunktion perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Jos

$$\frac{1}{n}M(\theta; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\theta; Y_i) u_i(\theta; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

Uskottavuusfunktion perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Jos

$$\frac{1}{n}M(\theta; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\theta; Y_i) u_i(\theta; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

- niin $\hat{\theta} \xrightarrow{P} \theta_0$ ja Lause 1.5 \Rightarrow

$$\frac{1}{n}M(\hat{\theta}; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\hat{\theta}; Y_i) u_i(\hat{\theta}; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta_0).$$

Uskottavuusfunktion perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Jos

$$\frac{1}{n}M(\theta; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\theta; Y_i) u_i(\theta; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

- niin $\hat{\theta} \xrightarrow{P} \theta_0$ ja Lause 1.5 \Rightarrow

$$\frac{1}{n}M(\hat{\theta}; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\hat{\theta}; Y_i) u_i(\hat{\theta}; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta_0).$$

- Vaihtoehtoinen Waldin testisuure:

$$W = \sqrt{n}(A\hat{\theta} - c)' \left[A (n^{-1}M(\hat{\theta}; \mathbf{Y}))^{-1} A' \right]^{-1} \sqrt{n}(A\hat{\theta} - c) \xrightarrow{H_0} \chi_q^2.$$

Uskottavuusfunktion perustuvia testejä

Waldin testi: Vaihtoehtoinen testisuure

- Jos

$$\frac{1}{n}M(\theta; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\theta; Y_i) u_i(\theta; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta) \quad \text{tasaisesti joukossa } \Theta,$$

- niin $\hat{\theta} \xrightarrow{P} \theta_0$ ja Lause 1.5 \Rightarrow

$$\frac{1}{n}M(\hat{\theta}; \mathbf{Y}) = \frac{1}{n} \sum_{i=1}^n u_i(\hat{\theta}; Y_i) u_i(\hat{\theta}; Y_i)' \xrightarrow{P} \bar{\mathcal{I}}(\theta_0).$$

- Vaihtoehtoinen Waldin testisuure:

$$W = \sqrt{n}(A\hat{\theta} - c)' \left[A (n^{-1}M(\hat{\theta}; \mathbf{Y}))^{-1} A' \right]^{-1} \sqrt{n}(A\hat{\theta} - c) \xrightarrow{H_0} \chi_q^2.$$

- Toisin kuin Hessen matriisi $-\mathcal{J}(\theta; \mathbf{y})$ on ulkotulomatriisi $M(\theta; \mathbf{Y})$ aina positiivisesti *semidefiniitti*.

Uskottavuusfunktion perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Waldin testi voidaan yleistää epälineaarille hypoteeseille

$$h(\theta_0) = 0,$$

Uskottavuusfunktion perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Waldin testi voidaan yleistää epälineaarille hypoteeseille

$$h(\theta_0) = 0,$$

- jossa

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Waldin testi voidaan yleistää epälineaarisille hypoteeseille

$$h(\theta_0) = 0,$$

- jossa

- $h : \Theta \rightarrow \mathbb{R}^q$ on jatkuvasti derivoituva ja

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Waldin testi voidaan yleistää epälineaarille hypoteeseille

$$h(\theta_0) = 0,$$

- jossa

- $h : \Theta \rightarrow \mathbb{R}^q$ on jatkuvasti derivoituva ja
- $q \times d$ derivaattamatriisi

$$H(\theta) = [\partial h_a(\theta) / \partial \theta_b], a = 1, \dots, q, b = 1, \dots, d,$$

toteuttaa $r(H(\theta_0)) = q$.

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Waldin testi voidaan yleistää epälineaarille hypoteeseille

$$h(\theta_0) = 0,$$

- jossa

- $h : \Theta \rightarrow \mathbb{R}^q$ on jatkuvasti derivoituva ja
- $q \times d$ derivaattamatriisi

$$H(\theta) = [\partial h_a(\theta) / \partial \theta_b], a = 1, \dots, q, b = 1, \dots, d,$$

toteuttaa $r(H(\theta_0)) = q$.

- Lineaarinen hypoteesi erikoistapauksena valitsemalla $h(\theta) = A\theta - c$.

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Waldin testi voidaan yleistää epälineaarille hypoteeseille

$$h(\theta_0) = 0,$$

- jossa

- $h : \Theta \rightarrow \mathbb{R}^q$ on jatkuvasti derivoituva ja
- $q \times d$ derivaattamatriisi

$$H(\theta) = [\partial h_a(\theta) / \partial \theta_b], a = 1, \dots, q, b = 1, \dots, d,$$

toteuttaa $r(H(\theta_0)) = q$.

- Lineaarinen hypoteesi erikoistapauksena valitsemalla $h(\theta) = A\theta - c$.
- Tässä tapauksessa Waldin testisuure on luontevaa perustaa suureeseen $h(\hat{\theta})$.

Uskottavuusfunktion perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Deltamenetelmä yleistys \Rightarrow nollahypoteesin voimassa ollessa

$$\sqrt{nh}(\hat{\theta}) \stackrel{as}{=} H(\theta_0) \sqrt{n}(\hat{\theta} - \theta_0).$$

Uskottavuusfunktion perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Deltamenetelmä yleistys \Rightarrow nollahypoteesin voimassa ollessa

$$\sqrt{n}h(\hat{\theta}) \stackrel{as}{=} H(\theta_0) \sqrt{n}(\hat{\theta} - \theta_0).$$

- Siis, Waldin testisuureksi saadaan

$$W = h(\hat{\theta})' [H(\hat{\theta}) \mathcal{J}(\hat{\theta}; \mathbf{Y})^{-1} H(\hat{\theta})']^{-1} h(\hat{\theta}) \xrightarrow{H_0} \chi_q^2,$$

jossa $\mathcal{J}(\hat{\theta}; \mathbf{Y})$:n paikalla voi olla $M(\hat{\theta}; \mathbf{Y})$.

Uskottavuusfunktion perustuvia testejä

Waldin testi: Epälineaarinen hypoteesi

- Deltamenetelmä yleistys \Rightarrow nollahypoteesin voimassa ollessa

$$\sqrt{n}h(\hat{\theta}) \stackrel{as}{=} H(\theta_0) \sqrt{n}(\hat{\theta} - \theta_0).$$

- Siis, Waldin testisuureksi saadaan

$$W = h(\hat{\theta})' [H(\hat{\theta}) \mathcal{J}(\hat{\theta}; \mathbf{Y})^{-1} H(\hat{\theta})']^{-1} h(\hat{\theta}) \xrightarrow{H_0} \chi_q^2,$$

jossa $\mathcal{J}(\hat{\theta}; \mathbf{Y})$:n paikalla voi olla $M(\hat{\theta}; \mathbf{Y})$.

- Käytännössä testaus sujuu samaan tapaan kuin edellä lineaarisen hypoteesin tapauksessa.

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.
- Nyt $\bar{\mathcal{I}}(\theta) = \text{diag}[\bar{\mathcal{I}}_{\psi\psi}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}(\theta)]$ ja $n^{-1} \mathcal{J}_o(\hat{\theta}; \mathbf{Y}) \xrightarrow{p} \bar{\mathcal{I}}(\theta_0)$, kun

$$\mathcal{J}_o(\hat{\theta}; \mathbf{Y}) = \text{diag}[\mathcal{J}_{\psi\psi}(\hat{\theta}; \mathbf{Y}) \quad \mathcal{J}_{\lambda\lambda}(\hat{\theta}; \mathbf{Y})].$$

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.
- Nyt $\bar{\mathcal{I}}(\theta) = \text{diag}[\bar{\mathcal{I}}_{\psi\psi}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}(\theta)]$ ja $n^{-1} \mathcal{J}_o(\hat{\theta}; \mathbf{Y}) \xrightarrow{P} \bar{\mathcal{I}}(\theta_0)$, kun

$$\mathcal{J}_o(\hat{\theta}; \mathbf{Y}) = \text{diag}[\mathcal{J}_{\psi\psi}(\hat{\theta}; \mathbf{Y}) \quad \mathcal{J}_{\lambda\lambda}(\hat{\theta}; \mathbf{Y})].$$

- Lisäksi,

$$(n^{-1} \mathcal{J}_o(\hat{\theta}; \mathbf{Y}))^{-1} \xrightarrow{P} \text{diag}[\bar{\mathcal{I}}_{\psi\psi}^{-1}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}^{-1}(\theta)].$$

Uskottavuusfunktioon perustuvia testejä

Waldin testi: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.
- Nyt $\bar{\mathcal{I}}(\theta) = \text{diag}[\bar{\mathcal{I}}_{\psi\psi}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}(\theta)]$ ja $n^{-1} \mathcal{J}_o(\hat{\theta}; \mathbf{Y}) \xrightarrow{P} \bar{\mathcal{I}}(\theta_0)$, kun

$$\mathcal{J}_o(\hat{\theta}; \mathbf{Y}) = \text{diag}[\mathcal{J}_{\psi\psi}(\hat{\theta}; \mathbf{Y}) \quad \mathcal{J}_{\lambda\lambda}(\hat{\theta}; \mathbf{Y})].$$

- Lisäksi,

$$(n^{-1} \mathcal{J}_o(\hat{\theta}; \mathbf{Y}))^{-1} \xrightarrow{P} \text{diag}[\bar{\mathcal{I}}_{\psi\psi}^{-1}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}^{-1}(\theta)].$$

- Saadaan Waldin testisuure

$$W_\psi = (A_\psi \hat{\psi} - c)' [A_\psi \mathcal{J}_{\psi\psi}^{-1}(\hat{\theta}; \mathbf{Y}) A_\psi']^{-1} (A_\psi \hat{\psi} - c) \xrightarrow{H_0} \chi_q^2.$$

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Tarkastellaan aluksi rajoitettua SU-estimaattoria $\tilde{\theta}$, joka maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Tarkastellaan aluksi rajoitettua SU-estimaattoria $\tilde{\theta}$, joka maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.
- Lineaarialgebraa käyttäen voidaan todeta, että

$$\underset{q \times d}{A} \underset{q \times 1}{\theta_0} = \underset{q \times 1}{c}, \quad r(A) = q \quad \Leftrightarrow \quad \theta_0 = \underset{d \times (d-q)}{B} \delta_0 + \underset{d \times 1}{e}, \quad r(B) = d - q$$

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Tarkastellaan aluksi rajoitettua SU-estimaattoria $\tilde{\theta}$, joka maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.
- Lineaarialgebraa käyttäen voidaan todeta, että

$$\underset{q \times d}{A} \underset{q \times 1}{\theta_0} = \underset{q \times 1}{c}, \quad r(A) = q \quad \Leftrightarrow \quad \underset{d \times (d-q)}{B} \underset{d \times 1}{\delta_0} + \underset{d \times 1}{e}, \quad r(B) = d - q$$

- Lisäksi, $AB = 0$ ja $\delta_0 = (B'B)^{-1} B'(\theta_0 - e)$, joten parametri δ saa arvoja joukossa $\Delta = \{\delta : \delta = (B'B)^{-1} B'(\theta - e), \theta \in \Theta\}$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Tarkastellaan aluksi rajoitettua SU-estimaattoria $\tilde{\theta}$, joka maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.
- Lineaarialgebraa käyttäen voidaan todeta, että

$$\underset{q \times d}{A} \underset{q \times 1}{\theta_0} = \underset{q \times 1}{c}, \quad r(A) = q \quad \Leftrightarrow \quad \underset{d \times (d-q)}{B} \underset{d \times 1}{\delta_0} + \underset{d \times 1}{e}, \quad r(B) = d - q$$

- Lisäksi, $AB = 0$ ja $\delta_0 = (B'B)^{-1} B'(\theta_0 - e)$, joten parametri δ saa arvoja joukossa $\Delta = \{\delta : \delta = (B'B)^{-1} B'(\theta - e), \theta \in \Theta\}$.
- Koska $\theta = B\delta + e$, on rajoitettu SU-estimaatti $\tilde{\theta} = B\tilde{\delta} + e$, jossa $\tilde{\delta}$ saadaan ratkaisemalla maksimointitehtävä

$$L^{(r)}(\tilde{\delta}; \mathbf{y}) = \max_{\delta \in \Delta} L^{(r)}(\delta; \mathbf{y}) = \max_{\delta \in \Delta} L(B\delta + e; \mathbf{y}).$$

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu pistemäärään $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$, jossa rajoitettu SU-estimaattori $\tilde{\theta} = B\tilde{\delta} + e$ siis maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu pistemäärään $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$, jossa rajoitettu SU-estimaattori $\tilde{\theta} = B\tilde{\delta} + e$ siis maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.
- Aikaisemmin esitettyjä tuloksia voidaan soveltaa myös estimaattoriin $\tilde{\delta}$ ja todeta erityisesti sen tarkentuvuus ja asymptoottinen normalisuus.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu pistemäärään $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$, jossa rajoitettu SU-estimaattori $\tilde{\theta} = B\tilde{\delta} + e$ siis maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.
- Aikaisemmin esitettyjä tuloksia voidaan soveltaa myös estimaattoriin $\tilde{\delta}$ ja todeta erityisesti sen tarkentuvuus ja asymptoottinen normalisuus.
- Rajoitetun SU-estimaattorin $\tilde{\theta}$ vastaavat ominaisuudet voidaan johtaa tästä käyttäen yhtälöä $\tilde{\theta} = B\tilde{\delta} + e$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu pistemäärään $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$, jossa rajoitettu SU-estimaattori $\tilde{\theta} = B\tilde{\delta} + e$ siis maksimoi uskottavuusfunktion ehdolla $A\theta = c$ ja toteuttaa siten $A\tilde{\theta} = c$.
- Aikaisemmin esitettyjä tuloksia voidaan soveltaa myös estimaattoriin $\tilde{\delta}$ ja todeta erityisesti sen tarkentuvuus ja asymptoottinen normaalisuus.
- Rajoitetun SU-estimaattorin $\tilde{\theta}$ vastaavat ominaisuudet voidaan johtaa tästä käyttäen yhtälöä $\tilde{\theta} = B\tilde{\delta} + e$.
- Tarkentuvuus, johon Raon testissä vedotaan, saadaan myös suoraan Lauseesta 2.2, kun parametriavaruus määritellään uudelleen korvaamalla Θ joukolla $\{\theta \in \Theta : A\theta = c\}$.

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Raon testin idea on tutkia poikkeako $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$ "liikaa" nolasta.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testin idea on tutkia poikkeako $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$ "liikaa" nolasta.
- Tarkentuvuus $\Rightarrow H_0$:n voimassa ollessa vapaa SUE $\hat{\theta}$ ja rajoitettu SUE $\tilde{\theta}$ toteuttavat $\hat{\theta} \approx \theta_0 \approx \tilde{\theta}$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testin idea on tutkia poikkeako $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$ "liikaa" nolasta.
- Tarkentuvuus $\Rightarrow H_0$:n voimassa ollessa vapaa SUE $\hat{\theta}$ ja rajoitettu SUE $\tilde{\theta}$ toteuttavat $\hat{\theta} \approx \theta_0 \approx \tilde{\theta}$.
- Koska $\hat{\theta}$ toteuttaa uskottavuusyhtälöt eli $s(\hat{\theta}; \mathbf{y}) = 0$, on H_0 :n voimassa ollessa odotettavaa, että $s(\tilde{\theta}; \mathbf{y}) \approx 0$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testin idea on tutkia poikkeako $s(\tilde{\theta}; \mathbf{y}) = \partial l(\tilde{\theta}; \mathbf{y}) / \partial \theta$ "liikaa" nollassa.
- Tarkentuvuus $\Rightarrow H_0$:n voimassa ollessa vapaa SUE $\hat{\theta}$ ja rajoitettu SUE $\tilde{\theta}$ toteuttavat $\hat{\theta} \approx \theta_0 \approx \tilde{\theta}$.
- Koska $\hat{\theta}$ toteuttaa uskottavuusyhtälöt eli $s(\hat{\theta}; \mathbf{y}) = 0$, on H_0 :n voimassa ollessa odotettavaa, että $s(\tilde{\theta}; \mathbf{y}) \approx 0$.
- Jos H_0 ei ole voimassa, ei ole mitään syytä miksi näin kävisi, joten pistemäärän $s(\tilde{\theta}; \mathbf{y})$ "suurien" arvojen voidaan tulkita viittaavan nollahypoteesin virheellisyyteen.

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Lausetta 2.3 perusteltaessa käytettiin kehitelmää

$$s(\hat{\theta}; \mathbf{Y}) = s(\theta_0; \mathbf{Y}) - \bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y})(\hat{\theta} - \theta_0), \quad (*)$$

jossa

$$\bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y}) \text{ :n } a. \text{ rivi} = \mathcal{J}(\bar{\theta}_a; \mathbf{Y}) \text{ :n } a. \text{ rivi ja}$$

$$\|\bar{\theta}_a - \theta_0\| \leq \|\hat{\theta} - \theta_0\|, \quad a = 1, \dots, d.$$

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Lausetta 2.3 perusteltaessa käytettiin kehitelmää

$$s(\hat{\theta}; \mathbf{Y}) = s(\theta_0; \mathbf{Y}) - \bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y})(\hat{\theta} - \theta_0), \quad (*)$$

jossa

$$\bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y}) \text{:n } a. \text{ rivi} = \mathcal{J}(\bar{\theta}_a; \mathbf{Y}) \text{:n } a. \text{ rivi ja}$$

$$\|\bar{\theta}_a - \theta_0\| \leq \|\hat{\theta} - \theta_0\|, \quad a = 1, \dots, d.$$

- Vastaava kehitelmä rajoitetun SUE:n $\tilde{\theta}$ tapauksessa on

$$s(\tilde{\theta}; \mathbf{Y}) = s(\theta_0; \mathbf{Y}) - \bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y})(\tilde{\theta} - \theta_0)$$

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Lausetta 2.3 perusteltaessa käytettiin kehitelmää

$$s(\hat{\theta}; \mathbf{Y}) = s(\theta_0; \mathbf{Y}) - \bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y})(\hat{\theta} - \theta_0), \quad (*)$$

jossa

$$\bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y}) \text{:n } a. \text{ rivi} = \mathcal{J}(\bar{\theta}_a; \mathbf{Y}) \text{:n } a. \text{ rivi ja}$$

$$\|\bar{\theta}_a - \theta_0\| \leq \|\hat{\theta} - \theta_0\|, \quad a = 1, \dots, d.$$

- Vastaava kehitelmä rajoitetun SUE:n $\tilde{\theta}$ tapauksessa on

$$s(\tilde{\theta}; \mathbf{Y}) = s(\theta_0; \mathbf{Y}) - \bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y})(\tilde{\theta} - \theta_0)$$

- tai, koska $\tilde{\theta} - \theta_0 = B(\tilde{\delta} - \delta_0)$,

$$s(\tilde{\theta}; \mathbf{Y}) = s(\theta_0; \mathbf{Y}) - \bar{\mathcal{J}}(\bar{\theta}; \mathbf{Y})B(\tilde{\delta} - \delta_0)$$

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu testisuureeseen

$$S = s(\tilde{\theta}; \mathbf{Y})' \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A' [A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A']^{-1} A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} s(\tilde{\theta}; \mathbf{Y})$$
$$\xrightarrow{H_0} \chi_q^2,$$

jolla on H_0 :n voimassa ollessa sama asympotoottinen jakauma kuin Waldin testisuurella.

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu testisuureeseen

$$S = s(\tilde{\theta}; \mathbf{Y})' \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A' [A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A']^{-1} A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} s(\tilde{\theta}; \mathbf{Y})$$
$$\xrightarrow{H_0} \chi_q^2,$$

jolla on H_0 :n voimassa ollessa sama asympotoottinen jakauma kuin Waldin testisuurella.

- Havaitun informaatiomatriisin $\mathcal{J}(\tilde{\theta}; \mathbf{Y})$ paikalla voidaan vaihtoehtoisesti käyttää ulkotulomatriisia $nM(\tilde{\theta}; \mathbf{Y})$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti

- Raon testi perustuu testisuureeseen

$$S = s(\tilde{\theta}; \mathbf{Y})' \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A' [A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A']^{-1} A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} s(\tilde{\theta}; \mathbf{Y})$$
$$\xrightarrow{H_0} \chi_q^2,$$

jolla on H_0 :n voimassa ollessa sama asympotoottinen jakauma kuin Waldin testisuurella.

- Havaitun informaatiomatriisin $\mathcal{J}(\tilde{\theta}; \mathbf{Y})$ paikalla voidaan vaihtoehtoisesti käyttää ulkotulomatriisia $nM(\tilde{\theta}; \mathbf{Y})$.
- Approksimatiiviset P-arvot

$$P = P_{H_0} \{S \geq S(\mathbf{y})\} \approx P \{\chi_q^2 \geq S(\mathbf{y})\}.$$

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Vaihtoehtoisia muotoiluja

- Käyttäen matriisilaskentaa voidaan testisuure

$$S = s(\tilde{\theta}; \mathbf{Y})' \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A' [A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} A']^{-1} A \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} s(\tilde{\theta}; \mathbf{Y})$$

sieventää yksinkertaiseen muotoon

$$S = s(\tilde{\theta}; \mathbf{Y})' \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} s(\tilde{\theta}; \mathbf{Y}) \xrightarrow[H_0]{d} \chi_q^2.$$

- Kun $A = [I_q : 0]$, ovat pistemäärän $s(\tilde{\theta}; \mathbf{Y})$ viimeiset $d - q$ komponenttia nollia ja testisuureen lauseke supistuu tilastollisen päättelyn kurssilla esitettyyn muotoon.
- Joissakin tapauksissa testisuureen lauseketta voidaan yksinkertaistaa myös käyttämällä havaitun informaatiomatriisin $\mathcal{J}(\tilde{\theta}; \mathbf{Y})$ paikalla ulkotulomatriisia $M(\tilde{\theta}; \mathbf{Y})$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Epälineaarinen hypoteesi

- Rajoitettu SU-estimointi ehdolla $h(\theta) = 0$ Lagrangen kerroinmenettelyä käyttäen: Maksimoidaan funktio

$$l(\theta, \kappa; \mathbf{y}) = l(\theta; \mathbf{y}) + \kappa' h(\theta),$$

jossa vektori $\kappa = [\kappa_1 \ \cdots \ \kappa_q]'$ sisältää Lagrangen kertoimet.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Epälineaarinen hypoteesi

- Rajoitettu SU-estimointi ehdolla $h(\theta) = 0$ Lagrangen kerroinmenettelyä käyttäen: Maksimoidaan funktio

$$l(\theta, \kappa; \mathbf{y}) = l(\theta; \mathbf{y}) + \kappa' h(\theta),$$

jossa vektori $\kappa = [\kappa_1 \ \cdots \ \kappa_q]'$ sisältää Lagrangen kertoimet.

- Derivointi θ :n suhteen ja gradientti $= 0 \Rightarrow$ yhtälö

$$\frac{\partial}{\partial \theta} l(\theta, \kappa; \mathbf{y}) = s(\theta; \mathbf{y}) + H(\theta)' \kappa = 0$$

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Epälineaarinen hypoteesi

- Rajoitettu SU-estimointi ehdolla $h(\theta) = 0$ Lagrangen kerroinmenettelyä käyttäen: Maksimoidaan funktio

$$l(\theta, \kappa; \mathbf{y}) = l(\theta; \mathbf{y}) + \kappa' h(\theta),$$

jossa vektori $\kappa = [\kappa_1 \cdots \kappa_q]'$ sisältää Lagrangen kertoimet.

- Derivointi θ :n suhteen ja gradientti $= 0 \Rightarrow$ yhtälö

$$\frac{\partial}{\partial \theta} l(\theta, \kappa; \mathbf{y}) = s(\theta; \mathbf{y}) + H(\theta)' \kappa = 0$$

- Sijoittamalla $\theta = \tilde{\theta}$ päädytään κ :n suhteen ratkaisuun

$$\tilde{\kappa} = -[H(\tilde{\theta}) \mathcal{J}(\tilde{\theta}; \mathbf{y})^{-1} H(\tilde{\theta})']^{-1} H(\tilde{\theta}) \mathcal{J}(\tilde{\theta}; \mathbf{y})^{-1} s(\tilde{\theta}; \mathbf{y}).$$

Uskottavuusfunktion perustuvia testejä

Raon pistemäärätesti: Epälineaarinen hypoteesi

- Rajoitettu SU-estimointi ehdolla $h(\theta) = 0$ Lagrangen kerroinmenettelyä käyttäen: Maksimoidaan funktio

$$l(\theta, \kappa; \mathbf{y}) = l(\theta; \mathbf{y}) + \kappa' h(\theta),$$

jossa vektori $\kappa = [\kappa_1 \ \cdots \ \kappa_q]'$ sisältää Lagrangen kertoimet.

- Derivointi θ :n suhteen ja gradientti $= 0 \Rightarrow$ yhtälö

$$\frac{\partial}{\partial \theta} l(\theta, \kappa; \mathbf{y}) = s(\theta; \mathbf{y}) + H(\theta)' \kappa = 0$$

- Sijoittamalla $\theta = \tilde{\theta}$ päädytään κ :n suhteen ratkaisuun

$$\tilde{\kappa} = -[H(\tilde{\theta}) \mathcal{J}(\tilde{\theta}; \mathbf{y})^{-1} H(\tilde{\theta})']^{-1} H(\tilde{\theta}) \mathcal{J}(\tilde{\theta}; \mathbf{y})^{-1} s(\tilde{\theta}; \mathbf{y}).$$

- Nähdään, että

$$S = \tilde{\kappa}' H(\tilde{\theta}) \mathcal{J}(\tilde{\theta}; \mathbf{Y})^{-1} H(\tilde{\theta})' \tilde{\kappa}.$$

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.
- Nyt $\bar{\mathcal{I}}(\theta) = \text{diag}[\bar{\mathcal{I}}_{\psi\psi}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}(\theta)]$ ja sekä

$$n^{-1} \mathcal{J}(\tilde{\theta}; \mathbf{Y}) \quad \text{että} \quad n^{-1} \mathcal{J}_o(\tilde{\theta}; \mathbf{Y}) = n^{-1} \text{diag}[\mathcal{J}_{\psi\psi}(\tilde{\theta}; \mathbf{Y}) \quad \mathcal{J}_{\lambda\lambda}(\tilde{\theta}; \mathbf{Y})]$$

estimoivat tarkentuvasti matriisia $\bar{\mathcal{I}}(\theta)$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Ortogonaalisten parametrien tapaus

- Ositetaan $\theta = (\psi, \lambda)$, jossa parametrit ψ ja λ ovat ortogonaaliset ja ψ on kiinnostava parametri.
- Testattava hypoteesi $H_0 : A_\psi \psi = c \Leftrightarrow A\theta = c$, jossa $A = [A_\psi : 0]$.
- Nyt $\bar{\mathcal{I}}(\theta) = \text{diag}[\bar{\mathcal{I}}_{\psi\psi}(\theta) \quad \bar{\mathcal{I}}_{\lambda\lambda}(\theta)]$ ja sekä

$$n^{-1} \mathcal{J}(\tilde{\theta}; \mathbf{Y}) \quad \text{että} \quad n^{-1} \mathcal{J}_o(\tilde{\theta}; \mathbf{Y}) = n^{-1} \text{diag}[\mathcal{J}_{\psi\psi}(\tilde{\theta}; \mathbf{Y}) \quad \mathcal{J}_{\lambda\lambda}(\tilde{\theta}; \mathbf{Y})]$$

estimoivat tarkentuvasti matriisia $\bar{\mathcal{I}}(\theta)$.

- Raon testissä voidaan havaittu informaatiomatriisi $\mathcal{J}(\tilde{\theta}; \mathbf{Y})$ korvata siten matriisilla $\mathcal{J}_o(\tilde{\theta}; \mathbf{Y})$.

Uskottavuusfunktioon perustuvia testejä

Raon pistemäärätesti: Ortogonaalisten parametrien tapaus

$$S = s(\tilde{\theta}; \mathbf{Y})' \mathcal{J}_o(\tilde{\theta}; \mathbf{Y})^{-1} A' [A \mathcal{J}_o(\tilde{\theta}; \mathbf{Y})^{-1} A']^{-1} A \mathcal{J}_o(\tilde{\theta}; \mathbf{Y})^{-1} s(\tilde{\theta}; \mathbf{Y})$$

jossa $A = [A_\psi : 0]$, $s(\tilde{\theta}; \mathbf{Y}) = (s_\psi(\tilde{\theta}; \mathbf{Y}), s_\lambda(\tilde{\theta}; \mathbf{Y}))$ ja

$$\mathcal{J}_o(\tilde{\theta}; \mathbf{Y}) = \text{diag}[\mathcal{J}_{\psi\psi}(\tilde{\theta}; \mathbf{Y}) \quad \mathcal{J}_{\lambda\lambda}(\tilde{\theta}; \mathbf{Y})]$$

Hieman matriisilaskentaa \Rightarrow testisuure

$$S_\psi = s_\psi(\tilde{\theta}; \mathbf{Y})' \mathcal{J}_{\psi\psi}^{-1}(\tilde{\theta}; \mathbf{Y}) A_\psi' [A_\psi \mathcal{J}_{\psi\psi}^{-1}(\tilde{\theta}; \mathbf{Y}) A_\psi']^{-1} A_\psi \mathcal{J}_{\psi\psi}^{-1}(\tilde{\theta}; \mathbf{Y}) s_\psi(\tilde{\theta}; \mathbf{Y})$$

tai vaihtoehtoisesti

$$S_\psi = s_\psi(\tilde{\theta}; \mathbf{Y})' \mathcal{J}_{\psi\psi}^{-1}(\tilde{\theta}; \mathbf{Y}) s_\psi(\tilde{\theta}; \mathbf{Y}) \xrightarrow{H_0} \chi_q^2.$$

Uskottavuusfunktion perustuvia testejä

Uskottavuusosamäärätesti

- Uskottavuusosamäärätesti perustuu testisuureeseen

$$LR = 2 [l(\hat{\theta}; \mathbf{Y}) - l(\tilde{\theta}; \mathbf{Y})] .$$

Uskottavuusfunktion perustuvia testejä

Uskottavuusosamäärätesti

- Uskottavuusosamäärätesti perustuu testisuureeseen

$$LR = 2 [l(\hat{\theta}; \mathbf{Y}) - l(\tilde{\theta}; \mathbf{Y})] .$$

- Intuitiivisesti selvää, että suuret LR:n arvot todistavat H_0 :aa vastaan.

Uskottavuusfunktion perustuvia testejä

Uskottavuusosamäärätesti

- Uskottavuusosamäärätesti perustuu testisuureeseen

$$LR = 2 [l(\hat{\theta}; \mathbf{Y}) - l(\tilde{\theta}; \mathbf{Y})] .$$

- Intuitiivisesti selvää, että suuret LR:n arvot todistavat H_0 :aa vastaan.
- LR:n asymptoottinen jakauma voidaan johtaa käyttäen toisen asteen Taylorin kehitelmää.

Uskottavuusfunktion perustuvia testejä

Uskottavuusosamäärätesti

- Uskottavuusosamäärätesti perustuu testisuureeseen

$$LR = 2 [l(\hat{\theta}; \mathbf{Y}) - l(\tilde{\theta}; \mathbf{Y})] .$$

- Intuitiivisesti selvää, että suuret LR:n arvot todistavat H_0 :aa vastaan.
- LR:n asymptoottinen jakauma voidaan johtaa käyttäen toisen asteen Taylorin kehitelmää.
- Kun $H_0 : \theta_0 = c (d \times 1)$, saadaan $\dots \dots$

Uskottavuusfunktion perustuvia testejä

Uskottavuusosamäärätesti

- Uskottavuusosamäärätesti perustuu testisuureeseen

$$LR = 2 [l(\hat{\theta}; \mathbf{Y}) - l(\tilde{\theta}; \mathbf{Y})] .$$

- Intuitiivisesti selvää, että suuret LR:n arvot todistavat H_0 :aa vastaan.
- LR:n asymptoottinen jakauma voidaan johtaa käyttäen toisen asteen Taylorin kehitelmää.
- Kun $H_0 : \theta_0 = c$ ($d \times 1$), saadaan $\dots \dots$



$$LR \stackrel{as}{\approx} (\hat{\theta} - c)' \mathcal{J}(\hat{\theta}; \mathbf{Y})(\hat{\theta} - c) \xrightarrow{H_0} \chi_d^2$$

Uskottavuusfunktion perustuvia testejä

Uskottavuusosamäärätesti

- Uskottavuusosamäärätesti perustuu testisuureeseen

$$LR = 2 [l(\hat{\theta}; \mathbf{Y}) - l(\tilde{\theta}; \mathbf{Y})] .$$

- Intuitiivisesti selvää, että suuret LR:n arvot todistavat H_0 :aa vastaan.
- LR:n asymptoottinen jakauma voidaan johtaa käyttäen toisen asteen Taylorin kehitelmää.
- Kun $H_0 : \theta_0 = c$ ($d \times 1$), saadaan $\dots \dots$



$$LR \stackrel{as}{\approx} (\hat{\theta} - c)' \mathcal{J}(\hat{\theta}; \mathbf{Y})(\hat{\theta} - c) \xrightarrow{H_0} \chi_d^2$$

- Yleiseinen tapaus algebraalisesti mutkikkaampi, mutta tulokseksi tulee

$$LR \xrightarrow{H_0} \chi_q^2 \quad (H_0: A\theta_0 = c, \quad A \quad q \times d).$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin

- Waldin testi perustuu vapaaseen SU-estimaattoriin ja Raon testi rajoitettuun SU-estimaattoriin.
- Waldin testi on siten usein kätevä tai luonteva, kun rajoittamaton malli on yksinkertainen ja sen parametrit on helppo estimoida. Raon testillä on puolestaan vastaava ominaisuus, kun rajoitettu malli on yksinkertainen ja sen parametrien estimointi on helppoa.
- Uskottavuusosamäärätesti on ”työlämpi” sikäli, että se vaatii sekä rajoitetun että rajoittamattoman SU-estimoinnin. Toisaalta, koska SU-estimaattori on tunnetusti invariantti vaihtoehtoïsille parametroinneille, on uskottavuusosamäärätestillä vastaava invarianssiominaisuus, jota Waldin testillä ja Raon testillä ei yleisesti ole.

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, $w_i = (y_i, x_i)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$, $W_i = (Y_i, X_i)$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, $w_i = (y_i, x_i)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$, $W_i = (Y_i, X_i)$
- Oletetaan, että analyysi voidaan perustaa ehdolliseen malliin

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

jossa $\mathbf{W}_i = (\mathbf{W}_1, \dots, \mathbf{W}_i)$ ja Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit eli joko

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, $w_i = (y_i, x_i)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$, $W_i = (Y_i, X_i)$
- Oletetaan, että analyysi voidaan perustaa ehdolliseen malliin

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

jossa $\mathbf{W}_i = (\mathbf{W}_1, \dots, \mathbf{W}_i)$ ja Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit eli joko

- $Z_i = (1, X_i)$ eli "tavanomaiseen" regressiomallia tai

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, $w_i = (y_i, x_i)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$, $W_i = (Y_i, X_i)$
- Oletetaan, että analyysi voidaan perustaa ehdolliseen malliin

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

jossa $\mathbf{W}_i = (\mathbf{W}_1, \dots, \mathbf{W}_i)$ ja Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit eli joko

- $Z_i = (1, X_i)$ eli "tavanomaiseen" regressiomallia tai
- $Z_i = (1, Y_{i-1}, X_i)$ eli autoregressiiviseen aikasarjamalli ulkopuolisin selittävin muuttujin ($Y_0 = y_0$ tunnettu vakio).

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Aineisto $\mathbf{w} = (w_1, \dots, w_n)$, $w_i = (y_i, x_i)$, vastaava sv $\mathbf{W} = (W_1, \dots, W_n)$, $W_i = (Y_i, X_i)$
- Oletetaan, että analyysi voidaan perustaa ehdolliseen malliin

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

jossa $\mathbf{W}_i = (\mathbf{W}_1, \dots, \mathbf{W}_i)$ ja Z_i ($p \times 1$) sisältää (\mathbf{W}_{i-1}, X_i) :n "relevantit" komponentit eli joko

- $Z_i = (1, X_i)$ eli "tavanomaiseen" regressiomallia tai
 - $Z_i = (1, Y_{i-1}, X_i)$ eli autoregressiiviseen aikasarjamalliin ulkopuolisin selittävin muuttujin ($Y_0 = y_0$ tunnettu vakio).
- Vaihtoehtoinen muotoilu

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Ehd. log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{z}_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Ehd. log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

- $H_0 : h(\beta) = 0$, $h : \mathbb{R}^p \rightarrow \mathbb{R}^q$ jatkuvasti derivoituva ja $H(\beta) = [\partial h_a(\beta) / \partial \beta_b]$, $(q \times p)$ toteuttaa $r(H(\beta)) = q$.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Ehd. log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

- $H_0 : h(\beta) = 0$, $h : \mathbb{R}^p \rightarrow \mathbb{R}^q$ jatkuvasti derivoituva ja $H(\beta) = [\partial h_a(\beta) / \partial \beta_b]$, $(q \times p)$ toteuttaa $r(H(\beta)) = q$.
- Konkreettinen esimerkki $H_0 : \beta_3 = \beta_1 \beta_2$.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Ehd. log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

- $H_0 : h(\beta) = 0$, $h : \mathbb{R}^p \rightarrow \mathbb{R}^q$ jatkuvasti derivoituva ja $H(\beta) = [\partial h_a(\beta) / \partial \beta_b]$, $(q \times p)$ toteuttaa $r(H(\beta)) = q$.
- Konkreettinen esimerkki $H_0 : \beta_3 = \beta_1 \beta_2$.
- $H_0 \Rightarrow$ malli on lineaarinen ja SU-estimointi hoituu helposti PNS:llä. Siten Waldin testi on kätevä.

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Ehd. log-uskottavuusfunktio

$$l^{(c)}(\beta, \sigma^2; \mathbf{w}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - z_i' \beta)^2, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

- $H_0 : h(\beta) = 0$, $h : \mathbb{R}^p \rightarrow \mathbb{R}^q$ jatkuvasti derivoituva ja $H(\beta) = [\partial h_a(\beta) / \partial \beta_b]$, $(q \times p)$ toteuttaa $r(H(\beta)) = q$.
- Konkreettinen esimerkki $H_0 : \beta_3 = \beta_1 \beta_2$.
- $H_0 \Rightarrow$ malli on lineaarinen ja SU-estimointi hoituu helposti PNS:llä. Siten Waldin testi on kätevä.
- Parametrit β ja σ^2 on todettu ortogonaalisiksi, joten Waldin testiä varten tarvitaan vapaan mallin SUE:t $\hat{\beta}$ ja $\hat{\sigma}^2$ sekä β :n havaittu informaatiomatriisi

$$\mathcal{J}_{\beta\beta}(\beta, \sigma^2; \mathbf{w}) := \frac{1}{\sigma^2} \sum_{i=1}^n Z_i Z_i' =: \frac{1}{\sigma^2} Q_n.$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Yleinen Waldin testisuure epälin. hypoteesin tapauksessa:

$$W = h(\hat{\theta})' [H(\hat{\theta}) \mathcal{J}(\hat{\theta}; \mathbf{Y})^{-1} H(\hat{\theta})']^{-1} h(\hat{\theta}) \xrightarrow[H_0]{d} \chi_q^2,$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Yleinen Waldin testisuure epälin. hypoteesin tapauksessa:

$$W = h(\hat{\theta})' [H(\hat{\theta}) \mathcal{J}(\hat{\theta}; \mathbf{Y})^{-1} H(\hat{\theta})']^{-1} h(\hat{\theta}) \xrightarrow{H_0} \chi_q^2,$$

- Yleinen Waldin testisuure lin. hypoteesin tapauksessa, kun parametrin $\theta = (\psi, \lambda)$ komponentit ortogonaaliset:

$$W_\psi = (A_\psi \hat{\psi} - c)' [A_\psi \mathcal{J}_{\psi\psi}^{-1}(\hat{\theta}; \mathbf{Y}) A_\psi']^{-1} (A_\psi \hat{\psi} - c) \xrightarrow{H_0} \chi_q^2.$$

Epälin. hypoteesin $H_0 : h(\psi) = 0$ tapauksessa vastaava "sijoituksilla"

$$A_\psi \hat{\psi} - c \rightarrow h(\hat{\psi}) \quad \text{ja} \quad A_\psi \rightarrow H(\hat{\psi}) = [\partial h_a(\psi) / \partial \psi_b].$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Epälineaaristen rajoitteiden testaus

- Yleinen Waldin testisuure epälin. hypoteesin tapauksessa:

$$W = h(\hat{\theta})' [H(\hat{\theta}) \mathcal{J}(\hat{\theta}; \mathbf{Y})^{-1} H(\hat{\theta})']^{-1} h(\hat{\theta}) \xrightarrow{H_0} \chi_q^2,$$

- Yleinen Waldin testisuure lin. hypoteesin tapauksessa, kun parametrin $\theta = (\psi, \lambda)$ komponentit ortogonaaliset:

$$W_\psi = (A_\psi \hat{\psi} - c)' [A_\psi \mathcal{J}_{\psi\psi}^{-1}(\hat{\theta}; \mathbf{Y}) A_\psi']^{-1} (A_\psi \hat{\psi} - c) \xrightarrow{H_0} \chi_q^2.$$

Epälin. hypoteesin $H_0 : h(\psi) = 0$ tapauksessa vastaava "sijoituksilla"

$$A_\psi \hat{\psi} - c \rightarrow h(\hat{\psi}) \quad \text{ja} \quad A_\psi \rightarrow H(\hat{\psi}) = [\partial h_a(\psi) / \partial \psi_b].$$

- Nyt $\mathcal{J}_{\psi\psi}(\hat{\theta}; \mathbf{Y})$:n paikalla on $\frac{1}{\sigma^2} \sum_{i=1}^n Z_i Z_i' =: \frac{1}{\sigma^2} Q_n$, joten saadaan

$$W_\beta = \frac{1}{\sigma^2} h(\hat{\beta})' [H(\hat{\beta}) Q_n^{-1} H(\hat{\beta})']^{-1} h(\hat{\beta}) \xrightarrow{H_0} \chi_q^2.$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Linearisessa mallissa on aikaisemmin olettu

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Linearisessa mallissa on aikaisemmin olettu

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

- tai

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Lineaarisisessa mallissa on aikaisemmin olettu

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

- tai

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Ehdollisten varianssien olettaminen vakioksi σ^2 voi olla kyseenalaista.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Linearisessa mallissa on aikaisemmin olettu

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2),$$

- tai

$$Y_i = Z_i' \beta + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \sim N(0, \sigma^2) \quad \underline{\underline{\quad}},$$

jossa $(\mathbf{W}_{i-1}, X_i) \quad \underline{\underline{\quad}} \quad \varepsilon_i$ ja siten $Z_i \quad \underline{\underline{\quad}} \quad \varepsilon_i$ kaikilla $i = 1, \dots, n$.

- Ehdollisten varianssien oletaminen vakioksi σ^2 voi olla kyseenalaista.
- Tarkastellaan tämän homoskedastisuusoletuksen testaamista Raon pistemäärätestillä, joka on tässä kätevä, koska nollahypoteen olettaa homoskedastisuuden ja SU-estimointi hoituu PNS:llä.

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Testiä varten yleistetään malli

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2).$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Testiä varten yleistetään malli

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2).$$

- Oletetaan $Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | (Z_i, V_i)$ ja

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\},$$

jossa v_i ($k \times 1$) ensimmäinen komponentti on vakio 1 ja muut komponenteiksi valitaan vektorin (\mathbf{w}_{i-1}, x_i) "relevantit" komponentit.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Testiä varten yleistetään malli

$$Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | Z_i \quad \text{ja} \quad Y_i | (Z_i = z_i) \sim N(z_i' \beta, \sigma^2).$$

- Oletetaan $Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | (Z_i, V_i)$ ja

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\},$$

jossa v_i ($k \times 1$) ensimmäinen komponentti on vakio 1 ja muut komponenteiksi valitaan vektorin (\mathbf{w}_{i-1}, x_i) "relevantit" komponentit.

- Parametrivektorille $\delta = (\delta_1, \delta_2, \dots, \delta_k)$ asetetaan nollahypoteesi

$$H_0 : \delta_2 = \dots = \delta_k = 0 \quad \Leftrightarrow \quad \sigma_i^2(\delta) = e^{\delta_1} := \sigma^2,$$

jonka voimassa ollessa homoskedastinen malli on riittävä.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Oletetaan siis $Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | (Z_i, V_i)$ ja

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\}.$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Oletetaan siis $Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | (Z_i, V_i)$ ja

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\}.$$

- Ehdolliseksi uskottavuusfunktiksi saadaan $(\theta = (\beta, \delta) \in \mathbb{R}^p \times \mathbb{R}^k)$

$$L^{(c)}(\theta; \mathbf{w}) = \prod_{i=1}^n \sigma_i^2(\delta)^{-1/2} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \frac{(y_i - z_i' \beta)^2}{\sigma_i^2(\delta)} \right\},$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Oletetaan siis $Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | (Z_i, V_i)$ ja

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\}.$$

- Ehdolliseksi uskottavuusfunktiksi saadaan $(\theta = (\beta, \delta) \in \mathbb{R}^p \times \mathbb{R}^k)$

$$L^{(c)}(\theta; \mathbf{w}) = \prod_{i=1}^n \sigma_i^2(\delta)^{-1/2} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \frac{(y_i - z_i' \beta)^2}{\sigma_i^2(\delta)} \right\},$$

- johon päädytään myös lähtemällä yhtälöstä

$$Y_i = Z_i' \beta + \sigma_i(\delta) \eta_i, \quad i = 1, \dots, n,$$

jossa $\eta_1, \dots, \eta_n \stackrel{\parallel}{\sim}$, $\eta_i \sim N(0, 1)$ ja $(\mathbf{W}_{i-1}, X_i) \stackrel{\parallel}{\perp} \eta_i \quad \forall i = 1, \dots, n.$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Oletetaan siis $Y_i | (\mathbf{W}_{i-1}, X_i) \stackrel{d}{=} Y_i | (Z_i, V_i)$ ja

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\}.$$

- Ehdolliseksi uskottavuusfunktiksi saadaan $(\theta = (\beta, \delta) \in \mathbb{R}^p \times \mathbb{R}^k)$

$$L^{(c)}(\theta; \mathbf{w}) = \prod_{i=1}^n \sigma_i^2(\delta)^{-1/2} \exp\left\{-\frac{1}{2} \sum_{i=1}^n \frac{(y_i - z_i' \beta)^2}{\sigma_i^2(\delta)}\right\},$$

- johon päädytään myös lähtemällä yhtälöstä

$$Y_i = Z_i' \beta + \sigma_i(\delta) \eta_i, \quad i = 1, \dots, n,$$

jossa $\eta_1, \dots, \eta_n \stackrel{i.i.d.}{\parallel}$, $\eta_i \sim N(0, 1)$ ja $(\mathbf{W}_{i-1}, X_i) \stackrel{i.i.d.}{\parallel} \eta_i \quad \forall i = 1, \dots, n$.

- $H_0 \Rightarrow \sigma_i(\delta) \eta_i = \sigma \eta_i \sim N(0, \sigma^2) \Rightarrow$ merkitsemällä $\varepsilon_i = \sigma \eta_i$ saadaan aikaisempi homoskedastinen tapaus

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Ehdollinen uskottavuusfunktio

$$L^{(c)}(\theta; \mathbf{w}) = \prod_{i=1}^n \sigma_i^2(\delta)^{-1/2} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \frac{(y_i - \mathbf{z}_i' \boldsymbol{\beta})^2}{\sigma_i^2(\delta)} \right\}.$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Ehdollinen uskottavuusfunktio

$$L^{(c)}(\theta; \mathbf{w}) = \prod_{i=1}^n \sigma_i^2(\delta)^{-1/2} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \frac{(y_i - \mathbf{z}_i' \beta)^2}{\sigma_i^2(\delta)} \right\}.$$

- $\sigma_i^2(\delta) = \exp\{v_i' \delta\}$ & logaritointi \Rightarrow

$$l^{(c)}(\theta; \mathbf{w}) = -\frac{1}{2} \sum_{i=1}^n v_i' \delta - \frac{1}{2} \sum_{i=1}^n \exp\{-v_i' \delta\} (y_i - \mathbf{z}_i' \beta)^2.$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Ehdollinen uskottavuusfunktio

$$L^{(c)}(\theta; \mathbf{w}) = \prod_{i=1}^n \sigma_i^2(\delta)^{-1/2} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \frac{(y_i - \mathbf{z}_i' \beta)^2}{\sigma_i^2(\delta)} \right\}.$$

- $\sigma_i^2(\delta) = \exp \{ \mathbf{v}_i' \delta \}$ & logaritointi \Rightarrow

$$l^{(c)}(\theta; \mathbf{w}) = -\frac{1}{2} \sum_{i=1}^n \mathbf{v}_i' \delta - \frac{1}{2} \sum_{i=1}^n \exp \{ -\mathbf{v}_i' \delta \} (y_i - \mathbf{z}_i' \beta)^2.$$

- Derivointi \Rightarrow

$$\frac{\partial}{\partial \beta} l^{(c)}(\theta; \mathbf{w}) = \sum_{i=1}^n \exp \{ -\mathbf{v}_i' \delta \} (y_i - \mathbf{z}_i' \beta) \mathbf{z}_i$$

ja

$$\frac{\partial}{\partial \delta} l^{(c)}(\theta; \mathbf{w}) = \frac{1}{2} \sum_{i=1}^n \left[\exp \{ -\mathbf{v}_i' \delta \} (y_i - \mathbf{z}_i' \beta)^2 - 1 \right] \mathbf{v}_i.$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Suoraviivainen lasku \Rightarrow parametrit β ja δ ovat ortogonaalisia \Rightarrow Raon testi voidaan perustaa pelkästään δ :n pistemäärään ja havaittuun infoon.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Suoraviivainen lasku \Rightarrow parametrit β ja δ ovat ortogonaalisia \Rightarrow Raon testi voidaan perustaa pelkästään δ :n pistemäärään ja havaittuun infoon.
- Edellinen laskettu. Jälkimmäistä varten lasketaan

$$\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\theta; \mathbf{w}) = -\frac{1}{2} \sum_{i=1}^n \exp\{-v_i' \delta\} (y_i - z_i' \beta)^2 v_i v_i'.$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Suoraviivainen lasku \Rightarrow parametrit β ja δ ovat ortogonaalisia \Rightarrow Raon testi voidaan perustaa pelkästään δ :n pistemäärään ja havaittuun infoon.
- Edellinen laskettu. Jälkimmäistä varten lasketaan

$$\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\theta; \mathbf{w}) = -\frac{1}{2} \sum_{i=1}^n \exp\{-v_i' \delta\} (y_i - z_i' \beta)^2 v_i v_i'.$$

- $Y_i = Z_i' \beta + \sigma_i(\delta) \eta_i, \quad i = 1, \dots, n,$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Suoraviivainen lasku \Rightarrow parametrit β ja δ ovat ortogonaalisia \Rightarrow Raon testi voidaan perustaa pelkästään δ :n pistemäärään ja havaittuun infoon.
- Edellinen laskettu. Jälkimmäistä varten lasketaan

$$\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\theta; \mathbf{w}) = -\frac{1}{2} \sum_{i=1}^n \exp\{-v_i' \delta\} (y_i - z_i' \beta)^2 v_i v_i'.$$

- $Y_i = Z_i' \beta + \sigma_i(\delta) \eta_i, \quad i = 1, \dots, n,$
- H_0 :n voimassa ollessa $\sigma_i(\delta) \eta_i = \sigma \eta_i = \varepsilon_i \sim N(0, \sigma^2)$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Suoraviivainen lasku \Rightarrow parametrit β ja δ ovat ortogonaalisia \Rightarrow Raon testi voidaan perustaa pelkästään δ :n pistemäärään ja havaittuun infoon.
- Edellinen laskettu. Jälkimmäistä varten lasketaan

$$\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\theta; \mathbf{w}) = -\frac{1}{2} \sum_{i=1}^n \exp\{-v_i' \delta\} (y_i - z_i' \beta)^2 v_i v_i'.$$

- $Y_i = Z_i' \beta + \sigma_i(\delta) \eta_i, \quad i = 1, \dots, n,$
- H_0 :n voimassa ollessa $\sigma_i(\delta) \eta_i = \sigma \eta_i = \varepsilon_i \sim N(0, \sigma^2)$
- Siis, $H_0 \Rightarrow$ lineaarinen mallin

$$Y_i = Z_i' \beta + \varepsilon_i, \quad i = 1, \dots, n,$$

josta testissä tarvittavat rajoitetut SUE:t saadaan helposti.

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Rajoitettu SUE mallista $Y_i = Z_i' \beta + \varepsilon_i \Rightarrow \tilde{\theta} = (\tilde{\beta}, \tilde{\delta}) = \tilde{\beta} = \hat{\beta}$ ja $\tilde{\delta} = (\tilde{\delta}_1, 0, \dots, 0)$, jossa $\tilde{\delta}_1 = \log \hat{\sigma}^2$ ja

$$\hat{\beta} = \left(\sum_{i=1}^n z_i z_i' \right)^{-1} \sum_{i=1}^n z_i y_i \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - z_i' \hat{\beta})^2.$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Rajoitettu SUE mallista $Y_i = Z_i' \beta + \varepsilon_i \Rightarrow \tilde{\theta} = (\tilde{\beta}, \tilde{\delta}) = \tilde{\beta} = \hat{\beta}$ ja $\tilde{\delta} = (\tilde{\delta}_1, 0, \dots, 0)$, jossa $\tilde{\delta}_1 = \log \hat{\sigma}^2$ ja

$$\hat{\beta} = \left(\sum_{i=1}^n z_i z_i' \right)^{-1} \sum_{i=1}^n z_i y_i \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - z_i' \hat{\beta})^2.$$

- Tarvittava δ :n pistemäärä

$$s_{\delta}(\tilde{\theta}; \mathbf{w}) := \frac{\partial}{\partial \delta} l^{(c)}(\tilde{\theta}; \mathbf{w}) = \frac{1}{2} \sum_{i=1}^n \left(\frac{(y_i - z_i' \tilde{\beta})^2}{\tilde{\sigma}^2} - 1 \right) v_i, \quad \tilde{\sigma}^2 = \hat{\sigma}^2.$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Rajoitettu SUE mallista $Y_i = Z_i' \beta + \varepsilon_i \Rightarrow \tilde{\theta} = (\tilde{\beta}, \tilde{\delta}) = \tilde{\beta} = \hat{\beta}$ ja $\tilde{\delta} = (\tilde{\delta}_1, 0, \dots, 0)$, jossa $\tilde{\delta}_1 = \log \hat{\sigma}^2$ ja

$$\hat{\beta} = \left(\sum_{i=1}^n z_i z_i' \right)^{-1} \sum_{i=1}^n z_i y_i \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - z_i' \hat{\beta})^2.$$

- Tarvittava δ :n pistemäärä

$$s_{\delta}(\tilde{\theta}; \mathbf{w}) := \frac{\partial}{\partial \delta} l^{(c)}(\tilde{\theta}; \mathbf{w}) = \frac{1}{2} \sum_{i=1}^n \left(\frac{(y_i - z_i' \tilde{\beta})^2}{\tilde{\sigma}^2} - 1 \right) v_i, \quad \tilde{\sigma}^2 = \hat{\sigma}^2.$$

- Tarvittava δ :n havaittu informaatio

$$\mathcal{J}_{\delta\delta}(\tilde{\theta}; \mathbf{w}) := -\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\tilde{\beta}, \tilde{\delta}; \mathbf{w}) = \frac{1}{2\tilde{\sigma}^2} \sum_{i=1}^n (y_i - z_i' \tilde{\beta})^2 v_i v_i'.$$

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- $\tilde{\beta} = \hat{\beta}$ ja $\tilde{\sigma}^2 = \hat{\sigma}^2$ tavalliset lineaarisen mallin $Y_i = Z_i' \beta + \varepsilon_i$ estimaattorit ja

$$\tilde{s}_\delta(\tilde{\theta}) := \frac{\partial}{\partial \delta} l^{(c)}(\tilde{\theta}; \mathbf{w}) = \frac{1}{2} \sum_{i=1}^n \left(\frac{(Y_i - Z_i' \tilde{\beta})^2}{\tilde{\sigma}^2} - 1 \right) V_i$$

$$\tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta}) := -\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\tilde{\theta}; \mathbf{w}) = \frac{1}{2\tilde{\sigma}^2} \sum_{i=1}^n (Y_i - Z_i' \tilde{\beta})^2 V_i V_i'$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- $\tilde{\beta} = \hat{\beta}$ ja $\tilde{\sigma}^2 = \hat{\sigma}^2$ tavalliset lineaarisen mallin $Y_i = Z_i' \beta + \varepsilon_i$ estimaattorit ja

$$\tilde{s}_\delta(\tilde{\theta}) := \frac{\partial}{\partial \delta} l^{(c)}(\tilde{\theta}; \mathbf{W}) = \frac{1}{2} \sum_{i=1}^n \left(\frac{(Y_i - Z_i' \tilde{\beta})^2}{\tilde{\sigma}^2} - 1 \right) V_i$$

$$\tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta}) := -\frac{\partial^2}{\partial \delta \partial \delta'} l^{(c)}(\tilde{\theta}; \mathbf{W}) = \frac{1}{2\tilde{\sigma}^2} \sum_{i=1}^n (Y_i - Z_i' \tilde{\beta})^2 V_i V_i'$$

- $H_0 : A\delta = 0$, jossa $A = [0 : I_{k-1}] \Rightarrow$ Raon testisuure

$$\begin{aligned} S_\delta &= \tilde{s}_\delta(\tilde{\theta})' \tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta})^{-1} A' [A \tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta})^{-1} A']^{-1} A \tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta})^{-1} \tilde{s}_\delta(\tilde{\theta}) \\ &= s_\delta(\tilde{\theta}; \mathbf{W})' \mathcal{J}_{\delta\delta}^{-1}(\tilde{\theta}; \mathbf{W}) s_\delta(\tilde{\theta}; \mathbf{W}) \end{aligned}$$

$$\xrightarrow{H_0} \chi_{k-1}^2$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Koska $Y_i - Z_i'\beta = \sigma_i(\delta)\eta_i$ (olettaen todelliset parametriarvot) ja $\eta_i \perp V_i$, niin H_0 :n voimassa ollessa

$$E[(Y_i - Z_i'\beta)^2] = \sigma^2 E(\eta_i^2) = \sigma^2$$

$$E[\mathcal{J}_{\delta\delta}(\theta; \mathbf{W})] = \frac{1}{2} \sum_{i=1}^n E(V_i V_i').$$

Uskottavuusfunktion perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Koska $Y_i - Z_i' \beta = \sigma_i(\delta) \eta_i$ (olettaen todelliset parametriarvot) ja $\eta_i \perp\!\!\!\perp V_i$, niin H_0 :n voimassa ollessa

$$E[(Y_i - Z_i' \beta)^2] = \sigma^2 E(\eta_i^2) = \sigma^2$$

$$E[\mathcal{J}_{\delta\delta}(\theta; \mathbf{W})] = \frac{1}{2} \sum_{i=1}^n E(V_i V_i').$$

- Siis, $\tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta}) = \mathcal{J}_{\delta\delta}(\tilde{\theta}; \mathbf{W})$ voidaan testisuureessa S_δ korvata matriisilla $\tilde{M}_{\delta\delta} = 2^{-1} \sum_{i=1}^n V_i V_i'$.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Koska $Y_i - Z_i'\beta = \sigma_i(\delta)\eta_i$ (olettaen todelliset parametriarvot) ja $\eta_i \perp\!\!\!\perp V_i$, niin H_0 :n voimassa ollessa

$$E[(Y_i - Z_i'\beta)^2] = \sigma^2 E(\eta_i^2) = \sigma^2$$

$$E[\mathcal{J}_{\delta\delta}(\theta; \mathbf{W})] = \frac{1}{2} \sum_{i=1}^n E(V_i V_i').$$

- Siis, $\tilde{\mathcal{J}}_{\delta\delta}(\tilde{\theta}) = \mathcal{J}_{\delta\delta}(\tilde{\theta}; \mathbf{W})$ voidaan testisuureessa S_δ korvata matriisilla $\tilde{M}_{\delta\delta} = 2^{-1} \sum_{i=1}^n V_i V_i'$.
- Saadaan testisuure

$$S_\delta^* = \tilde{s}_\delta(\tilde{\theta})' \tilde{M}_{\delta\delta}^{-1} A' \left[A \tilde{M}_{\delta\delta}^{-1} A' \right]^{-1} A \tilde{M}_{\delta\delta}^{-1} \tilde{s}_\delta(\tilde{\theta}) \xrightarrow{d} \chi_{k-1}^2$$

H_0 :n voimassa ollessa.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

Suoraviivaisilla matriisilaskelmilla nähdään, että testisuure

$$S_{\delta}^* = \tilde{s}_{\delta}(\tilde{\theta})' \tilde{M}_{\delta\delta}^{-1} A' \left[A \tilde{M}_{\delta\delta}^{-1} A' \right]^{-1} A \tilde{M}_{\delta\delta}^{-1} \tilde{s}_{\delta}(\tilde{\theta}) \xrightarrow{d} \chi_{k-1}^2$$

voidaan kirjoittaa

$$S_{\delta}^* = \frac{1}{2} \left(\sum_{i=1}^n \tilde{U}_i V_i' \right) \left(\sum_{i=1}^n V_i V_i' \right)^{-1} \left(\sum_{i=1}^n \tilde{U}_i V_i \right)$$

jossa $\tilde{U}_i = (Y_i - Z_i' \tilde{\beta})^2 / \tilde{\sigma}^2 - 1$ ja kuten aikaisemmin V_i on ehdollista heteroskedastisuutta selittävä muuttuja.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Johdettu testi perustui multiplikatiiviseen malliin

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\},$$

jossa v_i ($k \times 1$) ensimmäinen komponentti on vakio 1 ja muiksi komponenteiksi valitaan vektorin (\mathbf{w}_{i-1}, x_i) "relevantit" komponentit.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Johdettu testi perustui multiplikatiiviseen malliin

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\},$$

jossa v_i ($k \times 1$) ensimmäinen komponentti on vakio 1 ja muiksi komponenteiksi valitaan vektorin (\mathbf{w}_{i-1}, x_i) "relevantit" komponentit.

- $v_i = (1, \log x_{a,i})$, $x_{a,i}$ selittävän muuttujan vektorin x_i (positiivinen) a . komponentti $\Rightarrow \sigma_i^2(\delta) = \sigma^2 x_{a,i}^{\delta_2}$.

Uskottavuusfunktioon perustuvia testejä

Sovelluksia lineaariseen malliin: Heteroskedastisuuden testaus

- Johdettu testi perustui multiplikatiiviseen malliin

$$Y_i | (Z_i = z_i, V_i = v_i) \sim N(z_i' \beta, \sigma_i^2(\delta)), \quad \sigma_i^2(\delta) = \exp\{v_i' \delta\},$$

jossa v_i ($k \times 1$) ensimmäinen komponentti on vakio 1 ja muiksi komponenteiksi valitaan vektorin (\mathbf{w}_{i-1}, x_i) "relevantit" komponentit.

- $v_i = (1, \log x_{a,i})$, $x_{a,i}$ selittävän muuttujan vektorin x_i (positiivinen) a . komponentti $\Rightarrow \sigma_i^2(\delta) = \sigma^2 x_{a,i}^{\delta_2}$.
- Testisuureella S_δ^* lisäksi ns. invarianssiominaisuus eli samaan testisuureeseen päädytään olettamalla $\sigma_i^2(\delta) = h(v_i' \delta)$, jossa h on mikä tahansa kahdesti jatkuvasti derivoituva positiivinen funktio.