


Identifiointiprosessi

Alustavia kokeita



- Koesuunnittelu, identifiointikoe
- Mittaustulosten / datan esikäsittely
- Ei-parametriset menetelmät:
 - Transientti-, korrelaatio-, taajuus-, Fourier- ja spektraalianalyysi
=> askel-, impulssi- ja taajuusvaste, ajatuksia esim. kertaluvuista
- Parametrien estimointi – **mallirakenteen (rakenneparametrit) valinta**
- Mallin arviointi:
 - Simulointi, navat, erilaiset vasteet, jne...
- Mallin validointi:
 - Parametrien merkitsevyys, residuaalianalyysi, jne...

Mallirakenteen valinta

- Rakenteellinen – black box?
 - Rakenteellinen vaikea tuottaa, mutta usein vähemmän estimoitavaa => ”tarkempia” tuloksia
- Black-box: mallirakenne & kertaluvut?
 - Estimointimenetelmä (ARX –PNS, muut vaativat iteratiivisia)
 - Kertaluvut?
 - ARMA-, ARIMA-mallit oma tarinansa, ks. Mat-2.3128
 - Niukkuusperiaate (parsimony principle): valitse kahdesta tasaväkisestä mallista se, jossa on vähemmän parametreja
 - Miksi? Voidaan osoittaa, että ylimääräiset parametrit lisäävät ennustevirheen varianssia
- Käyttötarkoitus; mallinnusosaaminen; algoritminen kompleksisuus;...

Mallirakenteiden vertaaminen

- Helppoa! verrataan vaan jäännösneliösummia!
- Vai hetkinen... kun lisään tarpeeksi monta parametria, siitä tulee nolla!??
 - Tietyn rajan jälkeen malli alkaa sovittautua datan kohinaan
- Kupletin juoni ei olekaan estimointidataan sovittaminen vaan ilmiön kuvaaminen
- Ristiinvalidointi:
 - Mallin suorituskyvyn (esim. ennustuskyvyn) arviointi riippumattomalla datalla
- Kvantitatiivinen analyysi (vrt. lineaariset regressiomallit, ks. esim. Mat-2.2104):
 - Tilastollinen analyysi: pieneneekö hyvyysfunktio merkitsevästi kun siihen lisätään parametri?
 - Informaatiokriteerit: sakotetaan parametrien lisäämisestä
 - ”Selittäjien” kovarianssin singulaarisuus

F-testi

- Olkoot M_1 ja M_2 kaksi hierarkkista mallirakennetta (ts. M_1 saadaan M_2 :sta poistamalla parametri/parametreja)
- Ol. että kumpikin mallirakenne kuvaa systeemin niin, että ennustevirheet ovat valkoista kohinaa
- Tällöin testisuure $\chi = N(V_N^1 - V_N^2) / V_N^2$ on asympotoottisesti χ^2 - jakautunut vapauseilla $p_2 - p_1$
 - $p_i =$ parametrien lkm mallissa i
 - V_N^i hyvyyskriteerin arvo mallilla i
 - N havaintojen lukumäärä
- Idea: poikkeako testisuure nolasta tilastollisesti merkitsevästi kun siirrytään mallista 1 malliin 2?

Informaatiokriteerien idis

- Hyvyyskriteerin optimiarvo vs. parametrien lukumäärä d
- Tyypillinen funktionaalinen muoto: $W_N = \beta(d, N) V_N$
 - $V_N =$ parametreista (d kpl) riippuva ennustevirheiden neliösumma
 - β kasvaa kun d kasvaa ja vähenee kun N kasvaa
- Minimoi W_n in d :n ja parametrien suhteen
 \Rightarrow
Valitaan malli, jolle W_N on pienin

Informaatiokriteereitä

- Akaiken informaatiokriteeri (1972):

$$AIC = (1 + 2d/N)V_N$$

- Kullback-Leibler –etäisyysdellä (informaatioetäisyys) voidaan mitata kahden tn-jakauman etäisyyttä
- AIC:n minimoiva malli minimoi mallin ja systeemin informaatioetäisyyden

- Final Prediction Error (Akaike, 1969):

$$FPE = (1 + d/N) / (1 - d/N) V_N / N$$

- Keskimääräinen estimaatti ennustevirheen varianssille, kun estimaatti lasketaan muulla kuin mallin identifointiin käytetyllä datalla

- Rissanen minimipituuskriteeri (1978):

$$MDL = (1 + 2d \log N / N) V_N$$

- Kuvaa tilaa, joka tarvitaan mallin sisältämän informaation (mallin parametrit + ennustevirheet) tallentamiseksi pienimpään mahdolliseen tilaan

Hankel-matriisin testaus 1/2

- N:n kertaluvun järjestelmän impulssivaste $h(t)$ riippuu lineaarisesti n :stä edellisestä arvosta $h(t-1), \dots, h(t-n)$
 - Esim. $y(t) = -a_1 y(t-1) - a_2 y(t-2) + b_1 u(t-1) + b_2 u(t-2)$
 - $u(0) = 1, u(i) = 0$ kaikilla $i > 0$; $y(0) = y(-1) = y(-2) = 0$
- \Rightarrow Vaste $h(1) = b_1$; $h(2) = -a_1 h(1) + b_2$; $h(3) = -a_1 h(2) - a_2 h(1)$; ...; $h(t) = -a_1 h(t-1) - a_2 h(t-2)$ kaikilla $t > 2$
-

Määritellään Hankel-matriisi:

$$H(l, k) = \begin{bmatrix} h(k) & h(k+1) & \dots & h(k+l-1) \\ h(k+1) & h(k+2) & \dots & h(k+l-2) \\ \vdots & \vdots & \ddots & \vdots \\ h(k+l-1) & h(k+l-2) & \dots & h(k+2l-2) \end{bmatrix}$$

Hankel-matriisin testaus 2/2

- Järjestelmän kertaluku $n \Rightarrow H(l,k):n$ rangi = n kaikilla $l \geq n$
- Testaus: $\det(H(l,k)) = 0$ kun $l > n$
- Kohinaa \Rightarrow testataan perättäisten determinanttien suhteita: $D_1 = |\det(H(l,k))| / |\det(H(l+1,k))|$
- Determinantit voidaan keskiarvottaa yli $k:n$
- $l=n$ maksimoi $D_1:n$
- Käytännössä:
Transsienttianalyysi \Rightarrow impulssi/askelvaste \Rightarrow Hankel-matriisi $\Rightarrow D_1 \Rightarrow n$

Tulomomenttimatriisin testaus

- Olkoot järjestelmän kertaluku n ja u pe vähintään $n+1$
- Määr. $U(l)$:

$$U(l) = \left[\begin{array}{ccc|ccc} y(l) & \dots & y(1) & u(l) & \dots & u(1) \\ y(l+1) & \dots & y(2) & u(l+1) & \dots & u(2) \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ y(N) & \dots & y(N-l+1) & u(N) & \dots & u(N-l+1) \end{array} \right]$$

- Hae suurin $l = l^*$ jolla $U(l)$ vielä täyttä (rivi)rangia $\Rightarrow n=l^*$
 - hae suurin $l=l^*$ jolla $U(l)^T U(l)$ (tulomomenttimatriisi) täyttä rangia $\Rightarrow n=l^*$
- Käytännössä:
 - 1) Tee koe sopivalla herätteellä
 - 2) Etsi l^* eli n