

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...

Mallin validointi

- Koe suunniteltu, data kerätty, parametrit estimoitu, mallirakenne valittu
- Onko malli ”hyvä”?
 - Onko malli käyttötarkoitukseensa tarpeeksi hyvä? (tärkein pointti)
 - Onko malli sopusoinnussa havaitun datan kanssa? (validointi keskittyy tähän)
 - Kuvaako malli todellista systeemiä? (mahdotonta vastata pitävästi, validoinnilla tukea antavia tuloksia)
- Validointi = verrataan mallia mahdollisimman suureen todellisesta systeemistä peräisin olevaan tietomäärään

Validoinnin motivaatio

- Usein mahdotonta, kallista tai vaarallista kokeilla tosikäytössä kaikkia mahdollisia malleja
- Luottamus malliin luotava off-line
- Tärkeä mittatikka mallin käyttötarkoitus:
Voidaanko mallinnusprosessin motivaationa ollut ongelma ratkaista mallin avulla?
- Näkökulmia:
 - parametriestimaattien ominaisuudet
 - sisäänmeno-ulostulokäyttäytyminen
 - mallin redusoinnin vaikutus
 - simulointi ja ennustaminen
 - residuaalianalyysi

Parametriestimaattien ominaisuudet

- Rakenteelliset mallit: ovatko parametriestimaatit järkeviä?
 - esim. kitkakertoimien merkit oikein
- Parametrien herkkyysoanalyysi: simulointi hieman poikkeutetuin parametrialvoin (esim. luottamusvälin sisällä)
 - suuria poikkeamia => lisäidentifiointi tarpeen
- Black box-mallin parametriestimaattien luottamusvälit:
 - Estimaatit asympotoottisesti normaalijakautuneet
=> t-testattavissa
 - Nolla sisältyy luottamusväliin => parametri turha
 - Kaikkien estimaattien varianssit ja kovarianssit suuria
=> selittäjien kovarianssimatriisi on lähes singulaarinen (liian korkea kertaluku?)

Sisäänmeno-ulostulokäyttäytyminen

- Black box –malleilla tärkeä
- Lineaariset mallit \Rightarrow Boden diagrammi tärkeässä osassa
- Epälineaariset \Rightarrow simulointi
- Jos malli ei kuvaa systeemiä, saadaan estimoitaessa approksimaatio, joka riippuu
 - Koeolosuhteista
 - Esisuodatuksesta
 - Mallirakenteesta

\Rightarrow Parametristen mallien Boden diagrammien vertailu erilaisilla datoilla, esisuodatuksilla ja mallirakenteilla datasta estimoituun taajuusvaste-estimaattiin hyvä työkalu

Simulointi ja ennustaminen

- Usein mallin käyttötarkoitus
 - tärkeä rooli
- Simulointi riippumattoman datan ohjauksella ja riippumattoman ulostulon ennustaminen
 - nähdään suoraan millaisia ilmiöitä malli kuvaa, millaisia ei
- Mallin redusointi:
jos kertaluvuiltaan alennettu malli tuottaa oleellisesti saman sisäänmeno-ulostulokäytöksen, malli oli liian monimutkainen

Residuaalianalyysi

- Ennustevirheet kuvaavat sitä osuutta datassa, jota malli ei pysty kuvaamaan

$$\varepsilon(t) = y(t) - \hat{y}(t, \theta^{\wedge})$$

- ennustevirhe (”parametrien funktio”) = residuaali (”numeroita annetulla parametrillä”)
- Yksinkertaiset testit:

Olkoon meillä N arvoa (estimointi- tai validointidataa)

- $\max_N |\varepsilon(t)|$, $\frac{1}{N} \sum_{i=1}^N \varepsilon^2(t)$
- ”arvio maksimi- tai keskivirheistä; jos asiat eivät muutu, mallin ei tulisi koskaan tuottaa suurempia poikkeamia”

Residuaalien valkoisuus

- Oleellista on, että
 - residuaalit eivät riipu ohjauksesta $u(t)$ ja
 - residuaalit eivät riipu toisistaan
- => Ristikovarianssit oleellisesti nolliä $\hat{R}_{\varepsilon u}(\tau) = \frac{1}{N} \sum_{i=1}^N \varepsilon(t)u(t-\tau)$
 - intuitio: jos ennustevirhe riippuu $u(t)$ stä, ulostulo olisi voitu ennustaa paremmin ottamalla riippuvuus huomioon
- => Autokovarianssit oleellisesti nolliä $\hat{R}_{\varepsilon}(\tau) = \frac{1}{N} \sum_{i=1}^N \varepsilon(t)\varepsilon(t-\tau)$
 - intuitio: jos ennustevirhe riippuu menneistä virheistä, se olisi voitu ennustaa paremmin

Tilastollinen testaaminen 1/2

- Jos ohjaukset ja residuaalit ovat riippumattomia, ovat ristikorrelaatiot

$$x_\tau = \hat{R}_{\varepsilon u}(\tau) / \sqrt{R_\varepsilon(0)R_u(0)}$$

asymptoottisesti normaalijakautuneita $N(0, 1/N)$

- Suure

$$y = N \sum_{i=1}^m x_i^2 \xrightarrow{\text{dist}} \chi^2(m)$$

- Saadaan luottamusvälit
 - yksittäisille ristikorrelaatioille (95%: $|x_\tau| \leq 1.96/N^{0.5}$)
 - kaikille ristikorrelaatioille tiettyyn viiveeseen asti kerralla
- Huom! Korrelaatio negatiivisella τ :n arvolla voi olla merkki takaisinkytkennästä, ei väärästä mallirakenteesta

Tilastollinen testaaminen 2/2

- Vastaavasti autokorrelaatioille

$$\mathbf{x}_\tau = \hat{\mathbf{R}}_\varepsilon(\tau) / \mathbf{R}_\varepsilon(0)$$

- Pätee oletuksella että residuaalit ovat valkoista kohinaa:
 - yksittäinen autokorrelaatio asympotoottisesti normaalijakautunut $\mathbf{N}(0, 1/\mathbf{N})$ ja

$$y = N \sum_{i=1}^m x_i^2 \xrightarrow{\text{dist}} \chi^2(m)$$

- Saadaan luottamusvälit
 - yksittäisille autokorrelaatioille (95%: $|\mathbf{x}_\tau| \leq 1.96/\mathbf{N}^{0.5}$)
 - kaikille autokorrelaatioille tiettyyn viiveeseen asti kerralla

Muita testejä

- Residuaalien jakauma symmetrinen?
- H_0 : $\varepsilon(t)$ riippumaton ja symmetrisesti jakautunut

=>

$X_N = \text{”}\varepsilon(t)$:n etumerkin muutosten lkm sarjassa $\varepsilon(1), \dots, \varepsilon(N)$ ”
asymptoottisesti normaalijakautunut $N(N/2, N/4)$

- Vinouden laskeminen residuaalien histogrammille
- Onko residuaalit normaalijakautuneet? (ks. TAP, luento nro. 4)
 - χ^2 -yhteensopivuustesti
 - Otoksen vertaaminen annettuun (normaali) jakaumaan
 - Bowmanin ja Shentonin testi
 - Testisuure riippuu otoksen huipukkuudesta ja vinoudesta
 - Wilkin ja Shapiroin testi
 - Rankit-plot –kuvio ja korrelaatioimien neliö

Identifiointiprosessi

