

# Parametriset mallit

- Rakenteelliset mallit
  - parametreillä a priori tulkinta & merkitys
  - vrt. 3. harjoitustyö
- Black box-mallit
  - parametrit vain laskennan/sovituksen apuvälineitä
- Tarkastellaan pääosin lineaarisia diskreettiaikaisia black-box-malleja
- Tämän diasetin teemoja
  - malliluokat
  - parametrien estimointi - ennustevirhemenetelmä
  - mallin hyvyys vs. parametriestimaattien harhaisuus ja varianssi
  - systeemin / mallin identifioituvuus

# Rakenteelliset mallit

- Fysikaalisin tai vastaavin perustein rakennettuja malleja
  - osa parametreista tunnettu: esim. massat, poikkipinta-alat jne...
  - osa estimoitava: kitkakertoimet,...
- Merkintä  $\frac{d}{dx} x(t) = f(x(t), u(t), \theta); \hat{y}(t | \theta) = h(x(t), u(t), \theta)$ 

jossa  $\hat{y}(t | \theta)$  on mallin ennustettu ulostulo hetkellä  $t$  ja parametrivektorilla  $\theta$
- Edellä oletetaan valkoinen mittauskohina  $y(t) = h(x(t), u(t), \theta) + e(t)$ 
  - $E(y(t, \theta)) = \hat{y}(t, \theta)$
  - jos kohinalla on rakennetta, se kannattaa huomioida, esim. ARMA-malli
- Ennustevirhe  $\varepsilon(t) = y(t) - \hat{y}(t, \theta)$  (residuaali = ennustevirhe numerona)
- Estimointiongelma: etsi  $\theta$  s.e.  $\min V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \varepsilon^2(t, \theta)$

# Black box -mallit

- Yleinen lineaarinen diskreettiaikainen malli on muotoa  $y(t) = \eta(t) + w(t)$ 
  - $w(t)$  = häiriötermi
  - $\eta(t)$  = häiriötön ulostulo
- Termit muotoa  $\eta(t) = G(q, \theta)u(t)$ ,  $w(t) = H(q, \theta)e(t)$ 
  - $G()$  ja  $H()$  lineaarisia suotimia = diskreettiaikaisia siirtofunktioita
  - käytännössä rationaalisia (muotoa polynomi/polynomi) ja (asymptoottisesti) stabiileja (eräs validointitarkastelu)
  - $G(q, \theta) = B(q, \theta)/F(q, \theta)$ ,  $H(q, \theta) = C(q, \theta)/D(q, \theta)$
  - parametrivektori  $\theta$  koostuu polynomien  $B, F, C$  ja  $D$  kertoimista  $b_i, f_i, h_i, d_i$  ja kohinan  $e(t)$  varianssista
  - ”rakenneparametrit”  $n_b, n_c, n_d, n_f$  ja  $n_k$  (kuollut aika)

# Transfer function parameterizations

The transfer functions  $G(q)$  and  $H(q)$  in the linear model

$$y[k] = G(q; \theta)u[k] + H(q; \theta)e[k]$$

will be parameterized as

$$G(q; \theta) = q^{-n_k} \frac{b_0 + b_1 q^{-1} + \dots + b_{n_b} q^{-n_b}}{1 + f_1 q^{-1} + \dots + f_{n_f} q^{-n_f}}$$
$$H(q; \theta) = \frac{1 + c_1 q^{-1} + \dots + c_{n_c} q^{-n_c}}{1 + d_1 q^{-1} + \dots + d_{n_d} q^{-n_d}}$$

where the parameter vector  $\theta$  contains the coefficients  $\{b_k\}$ ,  $\{f_k\}$ ,  $\{c_k\}$ ,  $\{d_k\}$


Note:  $n_k$  determines dead-time,  $n_b, n_f, n_c, n_d$  order of transfer function polynomials.

# Erilaisia mallirakenteita


- Box-Jenkins (BJ):  $G(q)=B(q)/F(q)$ ,  $H(q)=C(q)/D(q)$ 
  - ”täydellinen” malli
  - systeemin ja kohinan mallit riippumattomia toisistaan
- Output error (OE):  $H(q)=1$  eli  $n_c=n_d=0$ 
  - kohina valkoista  $w(t)=e(t)$ , eli ei erityistä rakennetta
- ARMAX:  $A(q)y(t)=B(q)u(t)+C(q)e(t)$ 
  - kohina kokee saman dynamiikan kuin  $u$
  - järkevää kun kohina tulee prosessiin sen alkupäässä
- ARX:  $A(q)y(t)=B(q)u(t)+e(t)$  (myös *yhtälövirhemalli*)
  - ennustevirhe lineaarinen parametrien suhteen  $\Rightarrow$  parametrien estimointi ”helppoa” – tavallinen PNS
  - kohina kokee saman dynamiikan kuin  $u$ ; ei haittaa, jos signaali-kohina-suhde on hyvä
- Käyttö: määrää asteluvut, estimoi parametrit
  - käytännössä useita eri mallirakenteita ja astelukuja verrataan

# Mallirakenteita


ARMAX (autoregressive moving average  
exogeneous input)




BJ (Box Jenkins)



ARX (autoregressive with exogeneous input)



OE (output error)



# Mallin tuottama ennuste $\hat{y}(t)$

- Usein mallin käyttötarkoitus ennustaminen – tarvitaan myös ennustevirheen neliösummassa
- Millainen on kahdella edellisellä dialla esitettyjen mallien ennuste?
  - Malli muotoon  $y(t) = \text{JOTAIN} + e(t) \Rightarrow \hat{y}(t) = E(y(t)) = \text{JOTAIN}$ , koska  $E(e(t)) = 0$
- OE:  $\hat{y}(t, \theta) = G(q, \theta)u(t)$
- ARX:  $\hat{y}(t, \theta) = (1 - A(q))y(t) + B(q)u(t)$

Consider the linear model

$$y[k] = G(q)u[k] + H(q)e[k]$$

Multiply by  $H^{-1}(q)$  (to make noise term white) and re-write as

$$y[k] = (1 - H^{-1}(q))y[k] + H^{-1}(q)G(q)u[k] + e[k]$$

Since  $\{e\}$  is a white noise sequence, our best prediction is

$$\hat{y}[k] = (1 - H^{-1}(q))y[k] + H^{-1}(q)G(q)u[k]$$

# Mallien sovitus

- Ennustevirhemenetelmät: valitse  $\theta$  s.e. ennuste on ”hyvä”
  - toimiva hyvyyskriteeri ennustevirheen (otos)variانسsi
  - ennustevirhe  $\varepsilon(t) = y(t) - \hat{y}(t, \theta)$  ja  
hyvyyskriteeri
$$V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \varepsilon^2(t, \theta)$$
- $\hat{\theta}_N = \arg \min V_N(\theta)$ 
  - PNS on ennustevirhemenetelmien erikoistapaus
  - MIMO-mallit:  $\varepsilon^2(t)$  matriisiarvoinen, tarvitaan sopiva reaaliarvoinen kuvaus: det, trace, ...
- $V_N(\hat{\theta})$  on kohinan  $e(t)$  variانسsin estimaatti



# Lineaarinen regressio

- Regressio: malli muotoa  $y(t) = \theta^T \phi(t) + e(t)$ ,  $\phi(t)$  vektori, jossa viivästettyjä  $u(t)$ :n ja  $y(t)$ :n arvoja
  - $\theta$  sisältää viiveoperaattoripolynomien kertoimet
- $N$  mittausta  $\Rightarrow$  matriisi  $X = [\phi(1), \phi(2), \dots, \phi(N)]'$  sekä ulostulo  $Y(t) = [y(1), \dots, y(N)]' \Rightarrow \hat{\theta} = (X^T X)^{-1} X^T Y$
- Soveltuu ARX-mallien parametrien estimointiin
  - muut malliluokat epälineaarisia parametrien suhteen
- PNS-oletuksien syytä olla voimassa:
  - viivästetyt  $y$ :n ja  $u$ :n arvot keskenään kollineaarisia (koesuunnitteluongelma)  $\Leftrightarrow$  parametrit tehottomia (suuri varianssi) ja harhaisia, mutta tarkentuvia
  - $e$ :n homoskedastisuus (vakio varianssi)  $\Leftrightarrow$  parametrit tehottomia  $\Rightarrow$  painotettu PNS-estimointi
  - $e$ :n korreloimattomuus  $\Leftrightarrow$  parametrit tehottomia, harhaisia eivätkä tarkentuvia!  $\Rightarrow$  kohinalle jonkinlainen rakenne

# Iteratiivinen minimointi

- Mallit epälineaarisia parametrien suhteen
  - PNS ei onnistu
- Tarvitaan iteratiivinen menetelmä
  - kyseessä epälineaarinen rajoittamaton optimointitehtävä
- Gradienttimenetelmä:  $\theta^{k+1} = \theta^k - \alpha^k V_N'(\theta^k)$ 
  - $\alpha^k$  viivahaun avulla haettava askelpituus
- Toisen kertaluvun menetelmät: sovelletaan Newton-iterointia optimiratkaisun välttämättömiin ehtoihin
  - välttämätön ehto  $V_N'(\theta) = 0$
  - iterointi  $\theta^{k+1} = \theta^k - \alpha^k [V_N''(\theta^k)]^{-1} V_N'(\theta^k)$
- Tarvitaan  $V(\theta)$ :n eli  $\varepsilon(t)$ :n derivaatat parametrien suhteen
  - riippuvat mallirakenteesta; laskari #9, tehtävä #2

# Mikä on hyvä malli?

- Mallin laatu on yhteydessä mallin käyttötarkoitukseen
  - hyvä säätösuunnittelumalli voi olla huono simulointimalli
- Mallin laatu liittyy sen kykyyn kuvata systeemin toiminta
  - systeemin ja mallin ulostulot riittävän samanlaiset
- Hyvä malli yleistää, i.e., mallin ominaisuudet ”eivät riipu estimointidatasta” - mallin tilastolliset ominaisuudet
  - parametrien varianssi
    - varianssia voidaan pienentää kasvattamalla havaintojen lukumäärää
    - mallin ”variance error”
  - Estimaattien konvergenssi väärin arvoihin
    - väärä mallirakenne / puutteellinen koesuunnittelu
    - erotettava mallirakenteen vaikutus ja identifiointikokeen vaikutus
    - mallin ”bias error”

# Parametriestimaattien harhasta

- Mitä tapahtuu, kun  $N \rightarrow \infty$ ?
- Olkoon ennustevirheen varianssi  $E\varepsilon^2(t, \theta) = V(\theta)$
- Jos ennustevirhe  $\varepsilon(t, \theta)$  on valkoista kohinaa, niin

$$V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \varepsilon^2(t, \theta) \xrightarrow{N \rightarrow \infty} E\varepsilon^2(t, \theta) = V(\theta) \text{ w.p.1}$$

ja lisäksi  $\theta \xrightarrow{N \rightarrow \infty} \theta^* = \arg \min V(\theta)$


- Jos ennustevirhe ei ole korreloimaton (esim. väärä malli), niin estimaatti on harhainen ja konvergoituu väärään arvoon vs. ”oikean” mallin estimaatin arvo
- Estimaatti minimoi edelleen ennustevirheen varianssin
  - ”paras” malli väärästä malliluokasta

# Esimerkki: väärä mallirakenne

- Olkoon data peräisin ARMAX-prosessista
$$y(t) + a_0 y(t-1) = b_0 u(t-1) + e_0(t) + c_0 e_0(t-1)$$
- Sovitetaan ARX-malli  $\hat{y}(t | \theta) + a y(t-1) = b u(t-1)$
- Ennustevirheen varianssi on  $E(y(t) + a y(t-1) - b u(t-1))^2 = \dots = r_0(1 + a^2 - 2aa_0) + b^2 - 2bb_0 + 2ac_0$ 
  - ( $r_0 = E y^2(t)$ , ei riipu  $a$ :sta eikä  $b$ :stä)
- Ennustevirheen varianssin minimoivat  $\hat{a}$ ,  $\hat{b}$ :  $\hat{a} = a_0 - c_0 / r_0$ ;  $\hat{b} = b_0$ ;
  - $E \hat{a} \neq a_0$  eli estimaatti on harhainen
- Ennustevirheen varianssi näillä  $\hat{a}$ ,  $\hat{b}$  on  $1 + c_0^2 - c_0^2 / r_0$ 
  - todellisilla parametriarvoilla  $a_0$  ja  $b_0$  varianssi on  $1 + c_0^2$  eli suurempi

# Model structure matters!

**Example:**  $G(s) = 10/(s^2 + 2s + 10)$ , sampling time  $h = 0.05$ , noise variance  $0.1^2$



# Parametriestimaatin konvergenssi taajuustasossa

Assume that the true system is described by

$$y[k] = G_0(q)u[k] + w[k]$$



and that we try to estimate a model on the form ( $H_*(q)$  independent of  $\theta$ )

$$y[k] = G(q; \theta)u[k] + H_*(q)e[k]$$

$$\theta^* = \lim_{N \rightarrow \infty} \hat{\theta}_N = \arg \min \int_{-\pi}^{\pi} |G_0(e^{i\omega}) - G(e^{i\omega}, \theta)|^2 \frac{\Phi_u(\omega)}{|H_*(e^{i\omega})|^2} d\omega$$

- $V_N(\theta)$ :n minimoiva estimaatti lähestyy arvoa, joka saa mallin taajuusvasteen mahdollisimman lähelle systeemin taajuusvastetta painotettuna
  - ohjauksen spektrillä
  - kohinamallin taajuusvasteen käänteisluvulla
- Koesuunnittelu: valitaan  $u$ :n taajuusominaisuudet sopivasti  $\Rightarrow$  hyvä sovitus mielenkiintoisilla taajuuksilla

# Output error model using low- and high-frequency input signal





# Parametriestimaattien varianssi

- Oletetaan, että ennustevirhe  $\varepsilon(t, \theta)$  on valkoista kohinaa
- Tällöin parametriestimaatin  $\hat{\theta}_N$  kovarianssimatriisi  $P_N$  on

$$P_N = E(\hat{\theta}_N - \theta_0)(\hat{\theta}_N - \theta_0)^T \approx \frac{1}{N} \lambda \bar{R}^{-1}$$

jossa  $R = \psi(t, \theta_0)\psi^T(t, \theta_0)$  ja  $\psi(t, \theta) = d/d\theta y^{\wedge}(t, \theta)$

- $P_N$  riippuu
  - kohinan varianssista
  - datapisteiden lukumäärästä
  - ennusteen gradientista (herkkyys!)
- Parametriestimaatit asympotoottisesti normaalijakautuneita
  - tilastollisen merkitsevyyden testaus t-testillä
- Taajuusvasteen modulin varianssi annetulla parametriestimaatilla riippuu
  - parametrien lukumäärästä ja kohinan spektristä
  - datapisteiden lukumäärästä ja ohjauksen spektristä

$$\text{Var} \{G(e^{i\omega}; \theta)\} \approx \frac{n}{N} \frac{\Phi_w(\omega)}{\Phi_u(\omega)}$$

# Identifioituvuus

- Identifioituvuus: Voidaanko systeemin/mallin parametrit määrätä yksikäsitteisesti input-output –datasta?

Milloin ei voida?

- Kaksi erilaista parametrivektoria tuottaa samanlaisen mallin input-output –käyttäytymiseen
  - rakenteellinen identifioituvuus, ymmärretään systeemin ominaisuutena, vrt. harjoitustyö #3
- Kaksi erilaista parametrivektoria tuottaa erilaisen input-output-käyttäytymiseen ”hyvällä” inputilla, mutta puutteellinen input aiheuttaa samanlaiset ennusteet
  - ”deterministinen identifioituvuus”, ks. laskari #10, tehtävät #1 & #2

# Esimerkki rakenteellisesta identifioituvuudesta: tasavirtamoottori

- Valitaan tiloiksi kulma-asento  $y(t)$  ja  $\dot{y}$ -nopeus  $\omega(t)$  ja ohjaukseksi jännite  $u(t)$ :

$$\frac{d}{dt} x(t) = \begin{bmatrix} 0 & 1 \\ 0 & -1/\tau \end{bmatrix} x(t) + \begin{bmatrix} 0 \\ \beta/\tau \end{bmatrix} u(t),$$

- Tässä

$$\tau = \frac{JR_1}{fR_1 + k^2}, \quad \beta = \frac{k}{fR_1 + k^2}$$

- Systemissä on 5 parametriä, mutta mallissa vain 2
  - vaikka mallin parametrit saataisiin estimoitua, niistä saadaan vain 2 yhteyttä systemin parametrien välille
  - tällä parametroinnilla identifiointi ei onnistu – systeemi ei rakenteellisesti identifioituva

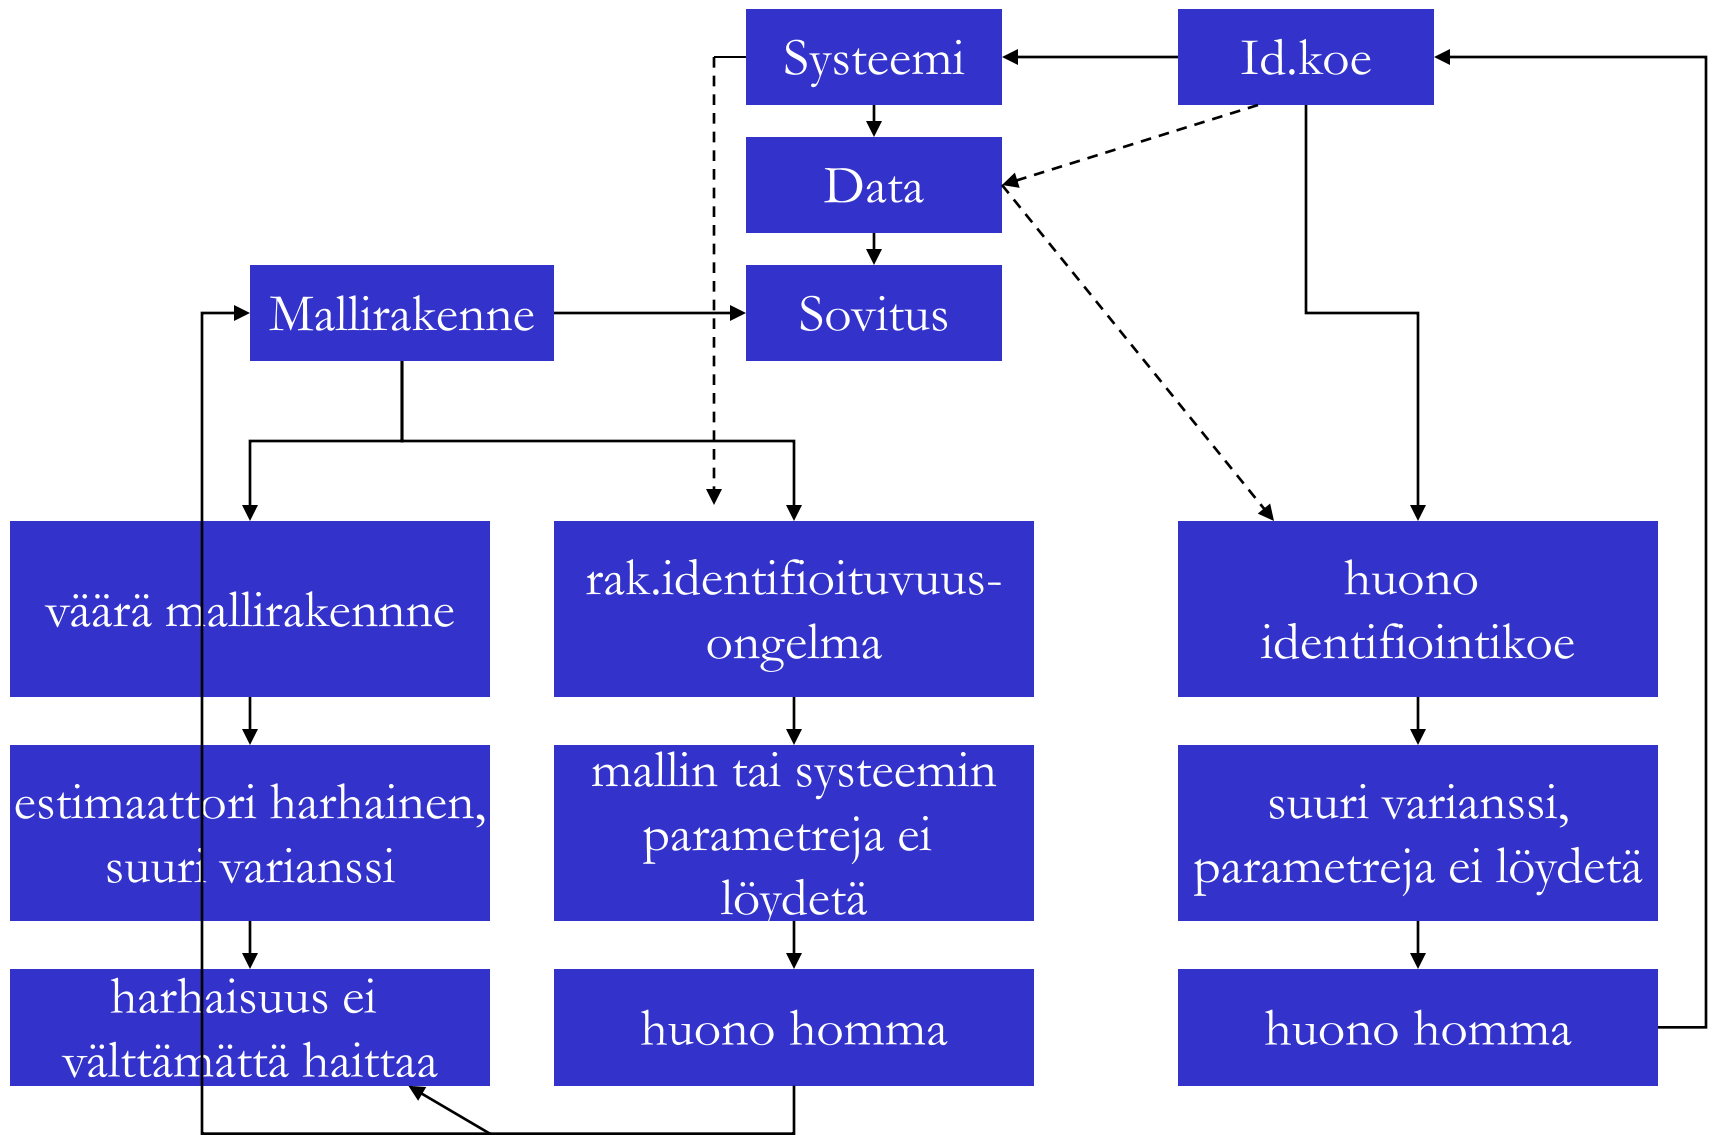
# Vaatimukset herätteelle

- Intuitiivisia tuloksia
  - identifiointikokeen pitäisi herättää systeemin mielenkiintoiset toimintatilat
  - sisäänmenon taajuussisältö oleellisessa asemassa
- Jatkuvasti herättävyyden käsite – tarkastellaan diasetillä #10
  - kvantitatiivisia tuloksia herätteen laadun ja parametriestimoinnin onnistumisen välille

# Esimerkki deterministisestä identifioituvuudesta

- ARX-malli  $\hat{y}(t | \theta) = au(t-1) + bu(t-2)$ ,  $\theta = (a \ b)'$ 
  - valitaan  $u$  vakio-ohjaus  $u_0$ :ksi
- Todellinen ennuste on tällöin  $\hat{y}(t | \theta) = (a+b)u_0(t-1)$ 
  - kaikki parametrit  $a$  ja  $b$ , joiden summa on sama, antavat saman ennusteen
- Malli (= parametrit  $a$  ja  $b$ ) ei ole identifioituvia (tällä herätteellä)
  - malli on kuitenkin rakenteellisesti identifioituva

# Estimoinnin ongelmalähteet



# Yhteenveto

- Perusidea: haetaan parametrivektori, joka minimoi ennustevirheen varianssin (=neliösumman)
  - parametriestimaatin varianssi riippuu kohinan varianssista, datan määrästä ja ennusteen herkkyydestä parametrin suhteen
- Lähestymistavan etuja
  - yleinen käytettävyys, monipuolisuus
  - tuloksena simulointiin soveltuva malli
- Haittoja, muttei välttämättä ylitsepääsemättömiä
  - tarvitaan näkemys systeemin rakenteesta