

# Identifiointiprosessi kokonaisuutena

- Alustavia kokeita*
- Koesuunnittelu, identifiointikoe
  - Mittaustulosten / datan esikäsittely
  - Ei-parametriset menetelmät
    - transientti-, korrelaatio-, taajuus-, Fourier- ja spektraalianalyysi => askel-, impulssi- ja taajuusvaste; ajatuksia esim. kertaluvuista
  - Mallirakenteen (rakenneparametrit) valinta
    - Parametrien estimointi
    - Mallirakenteiden vertaaminen
    - **Mallin arviointi**
      - **Simulointi, navat, erilaiset vasteet**
    - **Mallin validointi**
      - **Parametrien ominaisuudet, I-O-käyttäytyminen, residuaalianalyysi**

# Mallin validointi

- Koe suunniteltu, data kerätty, parametrit estimoitu, mallirakenne valittu
- Onko malli ”hyvä”?
  - Onko malli käyttötarkoitukseensa tarpeeksi hyvä?
  - *Onko malli sopuossuinnussa havaitun datan kanssa?*
  - *Kuvaako malli todellista systeemiä?*
- Validointi (eräs luonnehdinta): ”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 mittatikki mallin käyttötarkoitus

Voidaanko mallinnusprosessin motivaationa ollut ongelma ratkaista mallin avulla?

- **Näkökulmia**
  - **Parametrien ominaisuudet**
  - **Sisäänmeno-ulostulokäyttäytyminen**
  - **residuaalianalyysi**

# Parametriestimaattien ominaisuudet

- Rakenteelliset mallit: Ovatko parametriestimaatit järkeviä?
  - esim. kitkakertoimien merkit oikein
- Parametrien herkkyysoanalyysi: simulointi hieman poikkeutetuilla parametriarvoilla (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 => turhia selittäjiä – esim. liian korkea kertaluku?

# Sisäänmeno-ulostulokäyttäytyminen

- Black box –malleilla tärkeä
- Lineaariset mallit => Boden diagrammi tärkeässä osassa
  - Parametristen mallien Boden diagrammien vertailu erilaisilla datoilla, esisuodatuksilla ja mallirakenteilla datasta estimoituun taajuusvaste-estimaattiin hyvä työkalu
- Epälineaariset => simulointi

# Simulointi ja ennustaminen

- Usein mallin käyttötarkoitus
  - tärkeä rooli
- Simulointi *riippumattoman datan* ohjauksella ja riippumattoman ulostulon ennustaminen
  - nähdään esim. 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

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

- 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

$\Rightarrow$  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

$\Rightarrow$  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  $N(0, 1/N)$

- Luottamusväli yksittäiselle ristikorrelaatiolle 95%:  $|x_\tau| \leq 1.96/\sqrt{N}$

- Suure

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

- Testi siten, että  $H_0$ : Ohjaukset ja residuaalit ovat riippumattomia

- Huom.! Korrelaatio negatiivisella  $\tau$ :n arvolla voi olla merkki takaisinkytkennästä, ei väärästä mallirakenteesta

# Tilastollinen testaaminen 2/2

- Jos residuaalit ovat riippumattomia, ovat autokorrelaatiot

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

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

- Luottamusväli yksittäiselle autokorrelaatiolle 95%:  $|x_\tau| \leq 1.96/N^{0.5}$

- Suure

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

- Testi siten, että  $H_0$ : Residuaalit ovat riippumattomia

# The model development process

by Sargent

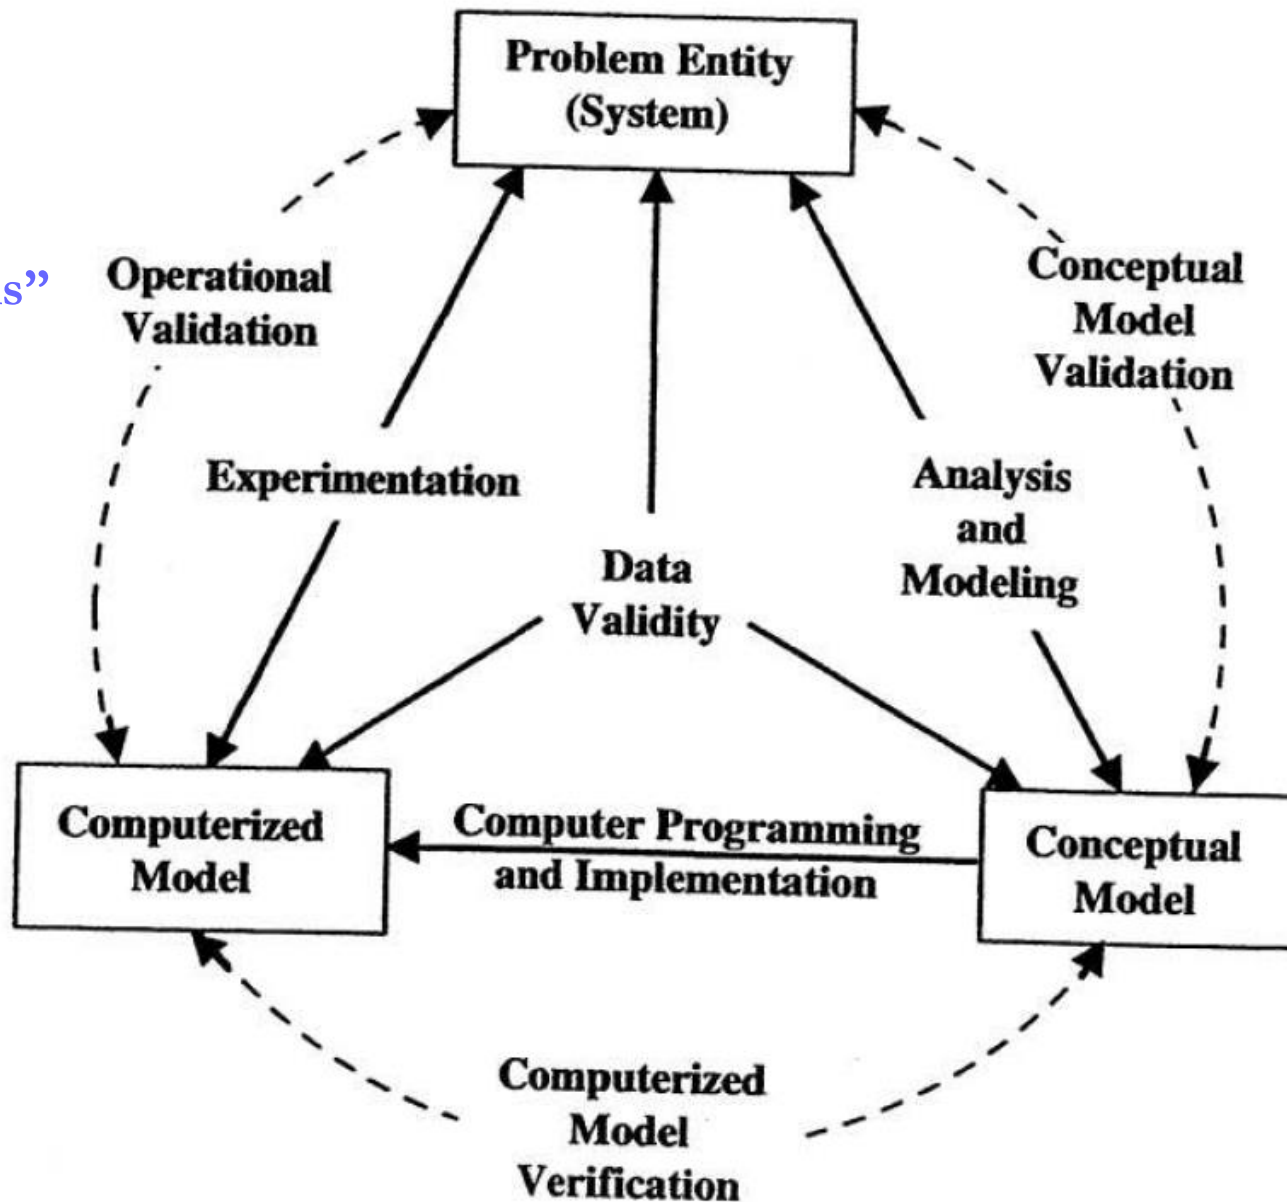
“Introductory tutorial on verification and validation of simulation models”

## **Verification**

Did we build the model right?

## **Validation**

Did we build the right model?



# The modeling-validating process

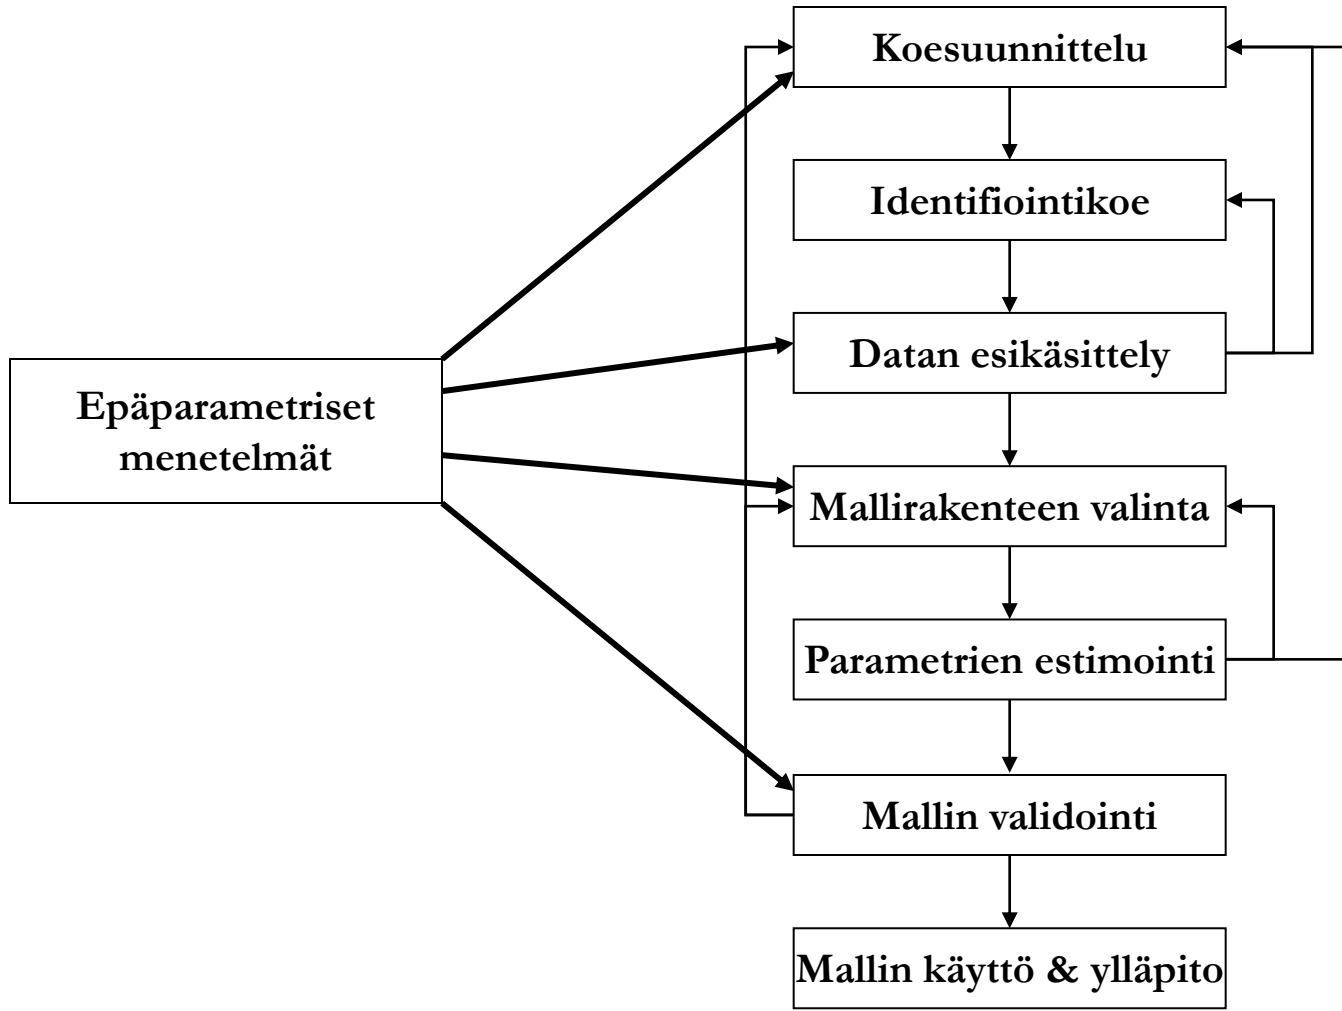
by Landry et al. “Model validation in OR”

---

<i>Face validation:</i>	Gathering of opinions about the reasonableness and accuracy of the model from people knowledgeable of the system. [32]
<i>Tracing</i>	Following the behaviour of specific entities through the model calculations.
<i>Internal validation</i>	Stochastic analysis to determine the variability of the model. [22,32].
<i>Sensitivity analysis</i>	Effects of changing input parameters on the model behaviour and its output. Comparison to other models in terms of structure and output. [2,6,9,11,23,43]
<i>Historical validation:</i>	Using part of historical data to determine if the model behaves as the system did. [1,32,43]
<i>Predictive validation:</i>	Determining if the system's behaviour and the model predictions are the same. [1,9,31]
<i>Events validation:</i>	Comparing the events occurrences in the model with the distribution of these in the system. [9]
<i>Turing tests:</i>	To verify if knowledgeable people can distinguish between the real system and model outputs.
<i>Spectral analysis:</i>	To evaluate if, in the frequency domain, the dynamic behaviour of the model differs from the behaviour of the system. [2,15,22,32,51,52]
<i>Experimentation:</i>	Manipulating variables in both the real-world and the model and then comparing the outputs.
<i>Convergent validation:</i>	Comparing the model's predictions with those of experts. [5]

---

# Identifiointiprosessi



# Näkökulmia mallintamiseen

- Mallin pätevyys- tai toiminta-alue
  - Identifiointikoe
  - Validointi pätevyysalueella
- Mallin oikeellisuus (validity): toiminta pätevyysalueella
- Mallin luotettavuus (credibility): toiminta pätevyysalueen ulkopuolella
- Miten luoda luotettavia malleja eikä pelkästään oikeita?
  - Laajempi pätevyysalue => luotettavuus
  - Vrt. Newtonin vetovoimalaki ja Ptolemaioksen käsitys aurinkokunnasta

# Kriittisyys mallia kohtaan

- Malli on oikea ja ehkä luotettava, ei koskaan ”oikea”
- Pääasia on systeemi ja ongelma, jota mallilla ratkaistaan, ei malli
- Yhteys olemassa olevaan teoriaan
  - ei kannata keksiä pyörää uudestaan
- Simulointituloksia tulkittaessa muistettava
  - mallissa/mallinnuksessa käytetyt oletukset
  - mallin tarkkuus ja approksimaatioiden taso

# Myyvä malli

- Tärkeä käytännön ongelma: Miten tilaaja saadaan ymmärtämään malli ja uskomaan sen toiminta?
- Mallintajan on ymmärrettävä mallin rakenne
- Mallintajan on pystyttävä kommunikoimaan malli erittäin yksinkertaisella tasolla
- Tilaajan on ymmärrettävä malli ja miten sen tulokset syntyvät
- Monimutkaisuuden
  - oltava aidosti tarpeen
  - oltava ymmärrettävää
  - tuotettava lisäarvoa



# Six simple principles of modeling 1/2

by Pidd M. “Just Modeling Through: A Rough Guide to Modeling,” *Interfaces*, Vol. 29, No. 2, 1999, pp. 118-132

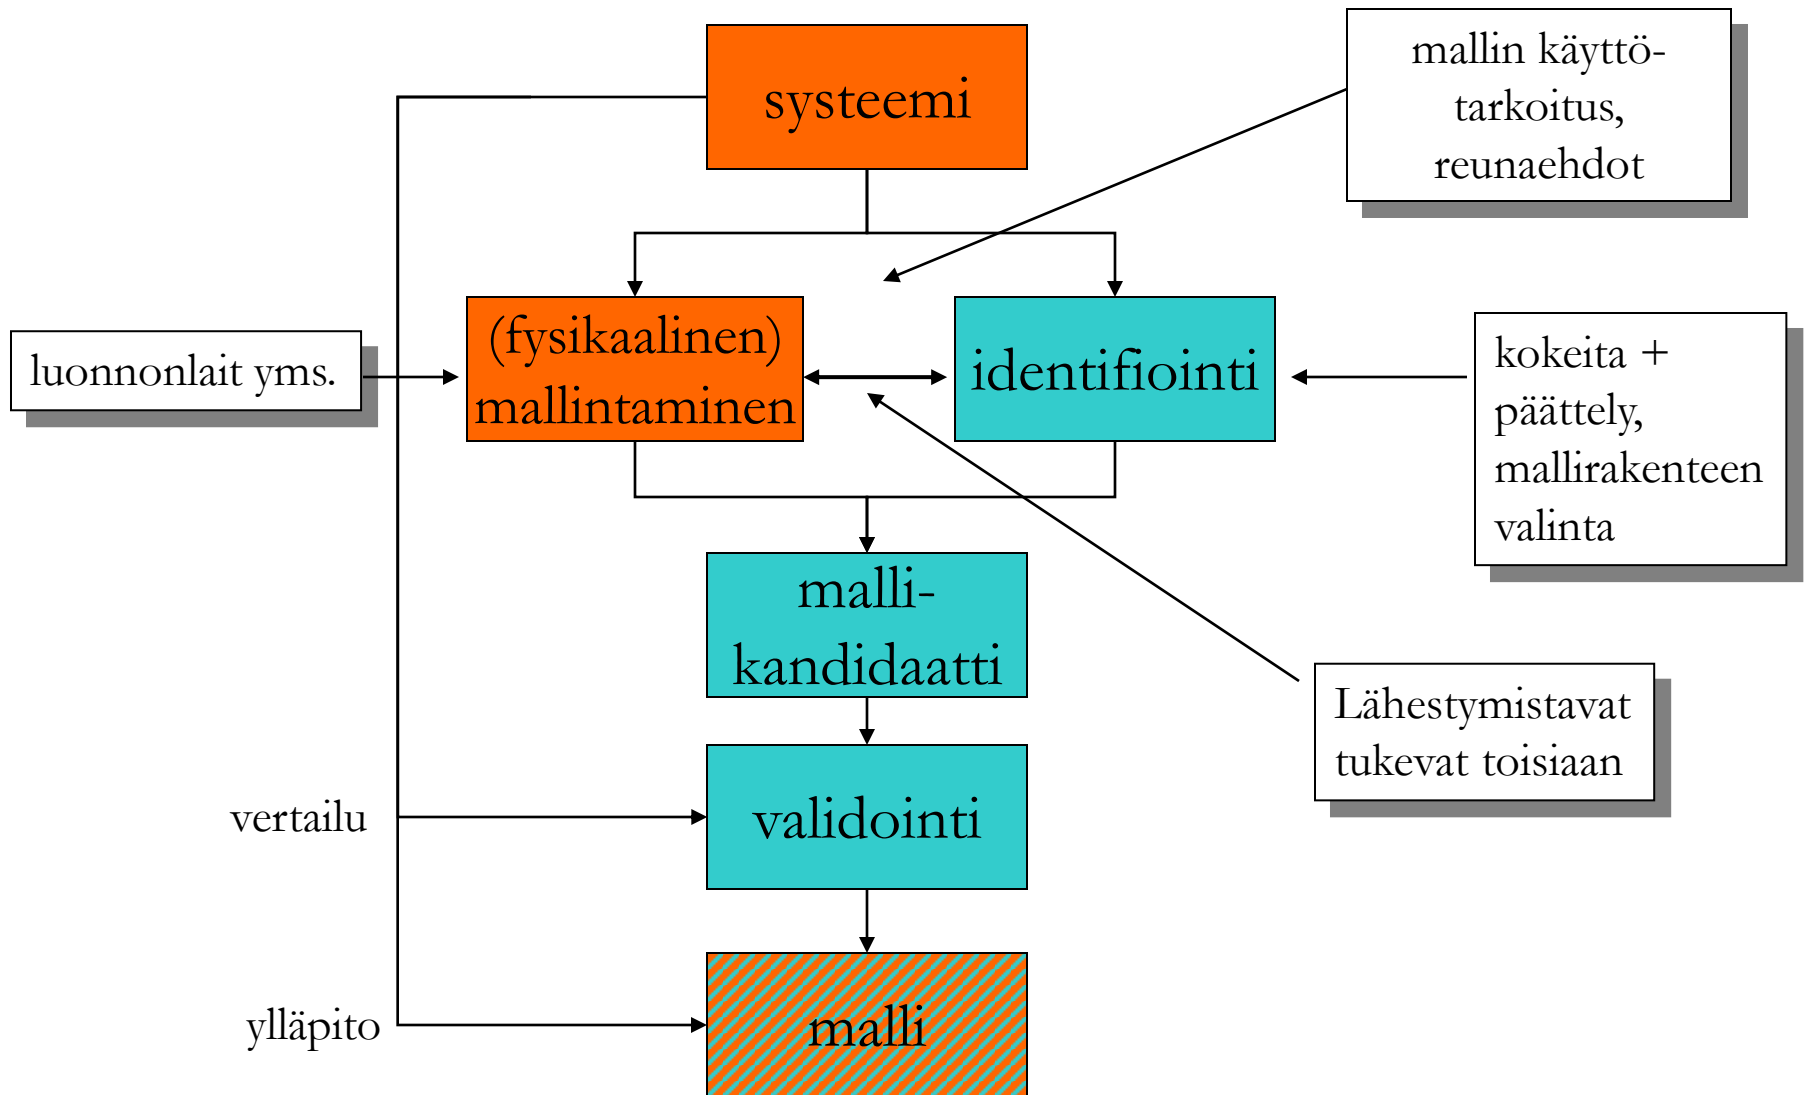
- Model simple - think complicated
  - Läpinäkyvyys, ymmärrettävyyys, perusteltavuus
  - Luottamus malliin syntyy paremmin, kun loppukäyttäjä ymmärtää mallin
  - Yksinkertainen malli voi tukea monimutkaista analyysia/päätöksentekoa
  - Mallit eivät korvaa ajattelua ja ihmisen päätöksentekoa – mallit toimivat päätöksenteon tukena
- Be parsimonious - start small and add
  - Aloita yksinkertaisesta mallista ja lisää yksityiskohtia
- Divide and conquer - avoid megamodels
  - Vältä isoja ja yleiskäyttöisiä malleja – eivät ole läpinäkyviä, perusteltavia, ymmärrettäviä & validointi mahdotonta
  - Joukko toistensa kanssa juttelevia pieniä malleja parempi kuin yksi iso

# Six simple principles of modeling 2/2

by Pidd M. “Just Modeling Through: A Rough Guide to Modeling” Interfaces, Vol. 29, No. 2, 1999, pp. 118-132

- Use metaphors, analogies, and similarities
  - ”Ei kannata keksiä pyörää uudestaan”
- Do not fall in love with data
  - Harhaluulo, että mallinnus ei onnistu, jos ei ole paljon dataa
  - Datan murskaaminen ei korvaa huolellista ajattelua
  - Mallinnus ohjaa datan keruuta eikä päinvastoin
  - Tieto = Data + Tulkinta
- Model building may feel like muddling through
  - “to manage to do something although you are not organized and do not know how to do it”

# Katsaus menneeseen



# Luennot 1-6

- Mallintaminen, dynaamisten systeemien mallit
  - Fysikaalinen mallintaminen vs. identifiointi (1)
  - Jatkuva-aikaisen tilamalli (2), input-output –kuvaus (2), siirtofunktiomalli (2)
  - Diskreettiaikainen tilamalli (3), input-output –kuvaus (3), siirtofunktiomalli (3)
  - Lineaaristen mallien ominaisuuksia (2, 3, 4, 5):
    - tasapainopiste, stabiilisuus, saavutettavuus, havaittavuus
  - Fysikaalinen mallinnusprosessi (4)
- Tilaestimointi
  - Tilaestimaattori (5)
  - Kalman suodin (6)
- Säättötekniikan alkeet
  - PID –säädin (6, 7)
  - Tilatakaisinkytkentä (7)

# Luennot 7-11

- Epäparametriset identifiointimenetelmät
  - Aikataso: impulssi- ja askelvaste  $\Leftrightarrow$  transientti- ja korrelaatioanalyysi (7, 8)
  - Taajuustaso: taajuusvaste  $\Leftrightarrow$  taajuus-, Fourier- ja spektraalianalyysi (8, 9)
- Parametriset mallit
  - Malliluokat (9)
  - Ennustevirhemenetelmä (9)
  - Parametriestimaattien ominaisuudet (10)
  - Identifioituvuus (9)
- Parametristen mallien identifiointiprosessi
  - Koesuunnittelu (10)
  - Datat esikäsittely (10)
  - Mallirakenteiden valinta ja vertailu (10, 11)
  - Mallin validointi (11)

# Jos kurssi vielä jatkuisi, niin voitaisiin tarkastella vaikkapa seuraavia teemoja....

- Rekursiivinen estimointi
  - parametriestimaattia päivitetään aina kun saadaan uutta dataa
- MIMO-mallit
- Tilamallien estimointi
- Suljetun silmukan systeemien identifiointi
- Epälineaariset black-box mallit
  - esim. neuroverkot

# Tenttivaatimukset

1. Kirja (Modeling of dynamic systems, Ljung & Glad) luvut 1-4, 8-10 ja 12, liitteet A, B ja C
    - kaavoja ei tarvitse opetella ulkoa, mutta merkitys syytä ymmärtää
    - luvusta 3 ei sivuja 54-61
  2. Luennot (luentokalvot + luennolla esitetyt asiat)
    - ks. luentojen sisällön tarkempi kuvaus
    - <https://mycourses.aalto.fi/course/view.php?id=36357&section=1>
  3. Laskuharjoitukset
    - eli nämä
    - <https://mycourses.aalto.fi/course/view.php?id=36357&section=2>
- Tentissä pääpaino kokonaisuuksilla ja asian ymmärtämisellä
    - simppelit laskut syytä osata
  - Tentti tiistaina 13.12.2022 klo 9-12