

TSFS06 Diagnos och övervakning

Föreläsning 5 - Konstruktion av teststorheter

Erik Frisk

Institutionen för systemteknik
Linköpings universitet
frisk@isy.liu.se

2017-04-05

1

Översikt

- Beteendemoder och beteendemodeller
- Teststorheten och modellvalidering
- Design av teststorheter
 - Prediktionsfel
 - Parameterskattningar
 - Likelihood-funktionen
- Avslutning

3

Ämnen för dagen

- En teststorhet är ett modellvalideringsmått för modell under nollhypotesen
- Vad är modell under nollhypotesen
- 4 allmänna principer för att konstruera teststorheter
 - prediktionsfel
 - residualer, konsistensrelationer och observatörer
 - parameterskattning
 - likelihood-funktionen
- Ej ortogonala och inga principer för när och hur.
- Idag kommer vi mest studera fallet då fel modelleras som avvikelser i konstanta parametrar (ej generella felsignaler).
- Verktygslåda/tänkesätt

Nästa gång: Tröskelsättning och försöka svara på frågan, hur bra är ett specifikt test?

2

Beteendemoder och felmodeller

Formalisering: Modellen $\mathcal{M}(\theta)$:

$$y(t) = \theta_1 u_1(t) + \theta_2 u_2(t) + \theta_3 u_3(t)$$

Beteendet beskrivs genom att för varje mod $F_p \in \{NF, F_1, F_2, F_3\}$ definiera vilka värden som θ kan anta.

$$F_p = NF \rightarrow \theta \in \Theta_{NF}$$

$$\Theta_{NF} = \{\theta | \theta = [1 \ 1 \ 1]\}$$

$$F_p = F_1 \rightarrow \theta \in \Theta_{F_1}$$

$$\Theta_{F_1} = \{\theta | \theta_1 \neq 1, \theta_2 = \theta_3 = 1\}$$

$$F_p = F_2 \rightarrow \theta \in \Theta_{F_2}$$

$$\Theta_{F_2} = \{\theta | \theta_2 \neq 1, \theta_1 = \theta_3 = 1\}$$

$$F_p = F_3 \rightarrow \theta \in \Theta_{F_3}$$

$$\Theta_{F_3} = \{\theta | \theta_3 \neq 1, \theta_1 = \theta_2 = 1\}$$

Θ_γ är feltillståndsrummet för mod F_γ (obs inget linjärt rum).

$$\theta \in \Theta = \cup_{\gamma \in \Omega} \Theta_\gamma$$

4

- Beteendemoder och beteendemodeller
- Teststorheten och modellvalidering
- Design av teststorheter
 - Prediktionsfel
 - Parameterskattningar
 - Likelihood-funktionen
- Avslutning

5

Teststorheten är ett modellvalideringsmått

Test T svarar alltså mot hypotestetet:

$$H^0 : \text{Modellen } \mathcal{M}(\theta), \text{ där } \theta \in \overbrace{\Theta_{NF} \cup \Theta_{F_1}}{=: \Theta_0}, \text{ är sann}$$
$$H^1 : \text{Modellen } \mathcal{M}(\theta), \text{ där } \theta \in \Theta_{NF} \cup \Theta_{F_1}, \text{ inte är sann.}$$

Teststorheten ska alltså indikera om nollhypotesen H^0 är sann eller inte, dvs. den skall vara ett modellvalideringsmått för modellen:

$$\mathcal{M}(\theta), \text{ där } \theta \in \Theta_0$$

7

Teststorheten är ett modellvalideringsmått

Betrakta

	NF	F ₁	F ₂	F ₃
T	0	0	X	X

Hypoteserna kan tecknas:

$$H^0 : F_p \in \{NF, F_1\}$$

$$H^1 : F_p \in \{F_2, F_3\}$$

Uttryckt med feltillstånd blir det:

$$H^0 : \text{Modellen } \mathcal{M}(\theta), \text{ där } \theta \in \Theta_{NF} \cup \Theta_{F_1}, \text{ är sann}$$

$$H^1 : \text{Modellen } \mathcal{M}(\theta), \text{ där } \theta \in \Theta_{NF} \cup \Theta_{F_1}, \text{ inte är sann.}$$

Detta kan också skrivas som:

$$H^0 : \theta \in \Theta_{NF} \cup \Theta_{F_1}$$

$$H^1 : \theta \notin \Theta_{NF} \cup \Theta_{F_1} \quad \text{dvs. } \theta \in \Theta_{F_2} \cup \Theta_{F_3}$$

6

Modellvalideringsmått, forts.

Titta lite noggrannare på testet.

$$H^0 : \theta \in \Theta_0 = \Theta_{NF} \cup \Theta_{F_1}$$

$$H^1 : \theta \notin \Theta_0$$

Feltillståndsvektorn under H^0 :

$$\Theta_0 = \{\theta | \theta_1 \in \mathbb{R}, \theta_2 = \theta_3 = 1\}$$

Modellen under H^0 :

$$y(t) = \theta_1 u_1(t) + u_2(t) + u_3(t)$$

dvs. vi ska hitta en teststorhet som är noll (liten) då modellen under H^0 är konsistent med observerade data, stora annars.

Teststorheten ska besvara om det finns något $\theta_1 \in \mathbb{R}$ så att modellen är konsistent med observationerna $\{y(t), u(t)\}_{t=1}^N$.

Exempel på sådan teststorhet:

$$T = \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - u_2(t) - u_3(t))^2$$

8

Hur beräknar vi T ?

En direkt, men en smula klumpig, ansats för att beräkna T är:

$$\begin{aligned} \frac{\partial}{\partial \theta_1} \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - u_2(t) - u_3(t))^2 &= \\ &= -2 \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - u_2(t) - u_3(t)) u_1(t) \end{aligned}$$

Vilket ger att det minimerande θ måste uppfylla ekvationen

$$\sum_{t=1}^N (y(t) - u_2(t) - u_3(t)) u_1(t) = \theta_1 \sum_{t=1}^N u_1^2(t)$$

9

Modellvalideringsmått, forts.

Vad blir teststorheten i fallet H_0 ? Antag ett feltillstånd $\theta^0 \in \Theta_0$, dvs observationerna genereras enligt:

$$y(t) = \theta_1^0 u_1(t) + u_2(t) + u_3(t)$$

Då blir teststorheten:

$$\begin{aligned} T &= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - u_2(t) - u_3(t))^2 = \\ &= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N (\theta_1^0 - \theta_1)^2 u_1(t)^2 = \left/ u_1(t) \equiv 0 \vee \hat{\theta}_1 = \theta_1^0 \right/ = 0 \end{aligned}$$

Modellen överensstämmer och måttet blir 0 då H_0 sann.

Normalt modelleras också brus i mätdata, vilket leder till att T får en fördelning under H_0 .

11

Hur beräknar vi T , forts.

Är $u_1(t) \equiv 0$ finns naturligt inget unikt minimerande θ_1 utan alla ger samma värde på T .

Vi kan därför beräkna teststorheten enligt

$$\begin{aligned} T &= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - u_2(t) - u_3(t))^2 = \\ &= \sum_{t=1}^N (y(t) - \hat{\theta}_1 u_1(t) - u_2(t) - u_3(t))^2 \end{aligned}$$

med

$$\hat{\theta}_1 = \begin{cases} \frac{\sum_{t=1}^N (y(t) - u_2(t) - u_3(t)) u_1(t)}{\sum_{t=1}^N u_1^2(t)} & \text{om } u_1(t) \not\equiv 0 \\ 1 & \text{annars} \end{cases}$$

En smula klumpig härledning och implementation av teststorheten. Återkommer till detta senare då vi pratar om linjär regression.

10

Modellvalideringsmått, forts.

Vad blir teststorheten i fallet att H_1 är sann? Betrakta ett fel F_2 med feltillstånd $\theta^1 \in \Theta_{F_2}$, dvs observationerna genereras enligt:

$$y(t) = u_1(t) + \theta_2^1 u_2(t) + u_3(t)$$

Då blir teststorheten:

$$\begin{aligned} T &= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - u_2(t) - u_3(t))^2 \\ &= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N ((1 - \theta_1) u_1(t) - (1 - \theta_2^1) u_2(t))^2 \end{aligned}$$

Låt

$$U_1 = [u_1(1) \quad u_1(2) \quad \cdots \quad u_1(N)]^T$$

$$U_2 = [u_2(1) \quad u_2(2) \quad \cdots \quad u_2(N)]^T$$

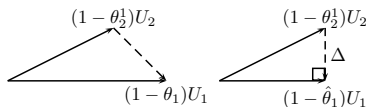
Då blir

$$T = \min_{\theta_1 \in \mathbb{R}} |(1 - \theta_1) U_1 - (1 - \theta_2^1) U_2|^2$$

12

$$T = \min_{\theta_1 \in \mathbb{R}} |(1 - \theta_1)U_1 - (1 - \theta_2^1)U_2|^2$$

Geometrisk tolkning:



$$T = \Delta^2$$

Fel F_2 detekteras om U_2 ej är parallell med U_1 .

Test T_1 svarar mot hypoteserna

$$H^0 : F_p \in \{NF, F_1\}, \quad H^1 : F_p \in \{F_2, F_3\}$$

Under H^0 gäller att f_1 är fri, $f_2 = f_3 = 0$. Modellen under noll-hypotesen, dvs modellen teststorheten T_1 skall validera blir

$$\begin{aligned} \dot{x}_1 &= g_1(x_1, x_2, f_1, u) \\ \dot{x}_2 &= g_2(x_1, x_2) \\ \dot{f}_1 &= 0 \\ y_1 &= h_1(x_1) \\ y_2 &= h_2(x_2) \end{aligned}$$

Här har vi kvar den fria signalen f_1 eftersom vi har en modell för hur den beter sig. Vi får inte "slänga bort" kunskapen att f_1 faktiskt är en konstant, okänd men konstant. Denna situation har vi inte för signalerna f_2 och f_3 .

Vad betyder egentligen $M(\theta), \theta \in \Theta_0$?

Antag en modell:

$$\begin{aligned} \dot{x}_1 &= g_1(x_1, x_2, f_1, u) \\ \dot{x}_2 &= g_2(x_1, x_2) \\ \dot{f}_1 &= 0 \\ y_1 &= h_1(x_1) + f_2 \\ y_2 &= h_2(x_2) + f_3 \end{aligned}$$

med de förväntade felmoderna F_1, F_2 , och F_3 .

Antag vi vill skapa residualer enligt

	F_1	F_2	F_3
T_1	0	X	X
T_2	X	0	X
T_3	X	X	0

Test T_3 då? Det testet svarar mot

$$H^0 : F_p \in \{NF, F_3\}, \quad H^1 : F_p \in \{F_1, F_2\}$$

Under H^0 gäller att f_3 är fri, $f_1 = f_2 = 0$. Modellen under noll-hypotesen, dvs modellen teststorheten T_3 skall validera är

$$\begin{aligned} \dot{x}_1 &= g_1(x_1, x_2, 0, u) \\ \dot{x}_2 &= g_2(x_1, x_2) \\ y_1 &= h_1(x_1) \end{aligned}$$

Modellen för test T_2 blir analog eftersom både f_2 och f_3 kommer in additivt på varsin mätsignal.

Modell under nollhypotesen, linjärt fall

Antag den linjära modellen med tre fel

$$H(p)x + L(p)z + F_1(p)f_1 + F_2(p)f_2 + F_3(p)f_3 = 0$$

och vi vill skapa residual r_1 med känslighet enligt

	F_1	F_2	F_3
r_1	0	X	X
r_2	X	0	X
r_3	X	X	0

dvs. vi vill skapa en residualgenerator, enligt tidigare föreläsningar, för att detektera observationer z utanför mängden

$$\mathcal{O}(F_1) = \{z | \exists x, f_1; H(p)x + L(p)z + F_1(p)f_1 = 0\}$$

Skriv om modellen med $x := (x, f_1)$ och $f := (f_2, f_3)$ enligt

$$(H(p) \quad F_1(p)) \begin{pmatrix} x \\ f_1 \end{pmatrix} + L(p)z + (F_2(p) \quad F_3(p)) \begin{pmatrix} f_2 \\ f_3 \end{pmatrix}$$

och använd metodiken.

17

Översikt

- Beteendemoder och beteendemodeller
- Teststorheten och modellvalidering
- Design av teststorheter
 - Prediktionsfel
 - Parameterskattningar
 - Likelihood-funktionen
- Avslutning

19

Sammanfattning, en arbetsgång, ett tänk

Arbetsgång

- 1 Teckna tänkt beslutsstruktur
- 2 För varje test i systemet, ta fram modellen under nollhypotesen (det underlättar om man faktiskt skriver ned den)
- 3 Konstruera ett modellvalideringsmått för modellen, dvs. generera en signal som är 0 (eller liten) om modellen faktiskt kan vara sann.

18

Allmän princip för design av teststorheter

Konstruera en teststorhet som är liten om vi kan anpassa modellen

$$\mathcal{M}(\theta), \quad \theta \in \Theta_0$$

till observationerna (uppmätta data). Notera att modellen under nollhypotesen kan vara signifikant enklare än den generella modellen med alla felmoder inkluderade.

Antag:

$$V(\theta, [u, y])$$

vara ett generellt modellvalideringsmått för modellen $\mathcal{M}(\theta)$ med avseende på data $[u, y]$.

Då är

$$T = \min_{\theta \in \Theta_0} V(\theta, [u, y])$$

liten under nollhypotesen och (förhoppningsvis) stor annars, dvs ett mått på konsistens mellan modell och uppmätta data.

20

Design av teststorheter baserat på:

- residualer
konsistensrelationer, observatörer
(ej nu, vi har gjort det för linjära modeller och vi återkommer till det i senare föreläsning)

1. prediktionsfel
2. parameterskattningar
3. likelihood-funktionen

Finns fler och detta är ingen ortogonal(disjunkt) klassificering!
Dessa principer kan kombineras för olika felmodeller.

21

Översikt

- *Beteendemoder och beteendemodeller*
- *Teststorheten och modellvalidering*
- *Design av teststorheter*
 - *Prediktionsfel*
 - *Parameterskattningar*
 - *Likelihood-funktionen*
- *Avslutning*

23

$$V(x) = (x_1 - 2)^2 + (x_2 - 4)^2$$

$$\min_x V(x) = 0$$

$$\arg \min_x V(x) = \begin{pmatrix} 2 \\ 4 \end{pmatrix}$$

$$\arg \min_{x_1} \min_x V(x) = 2$$

22

Teststorhet baserad på prediktionsfelen

Exempel på modellvalideringsmått för modell $M(\theta)$ för ett fixt θ :

$$V(\theta, z) = \frac{1}{N} \sum_{t=1}^N \|y(t) - \hat{y}(t|\theta)\|$$

Om Θ^0 består av ett enda värde:

$$T(z) = V(\theta_0, z)$$

\Rightarrow ett modellvalideringsmått för modellen $\mathcal{M}(\theta_0)$

Om Θ^0 är en mängd av flera värden:

$$T(z) = \min_{\theta \in \Theta^0} V(\theta, z)$$

\Rightarrow ett modellvalideringsmått för modellen $\mathcal{M}(\theta)$, $\theta \in \Theta_0$

Notera: avkoppling

24

Exempel: Förstärkning och bias

$$y(t) = gu(t) + b + v(t) \quad v(t) \in N(0, \sigma^2) \quad \theta = [b, g]$$

Betrakta felmoderna:

NF	$g = 1, b = 0$	“no fault”
F_b	$g = 1, b \neq 0$	“bias fault”
F_g	$g \neq 1, b = 0$	“gain fault”

Konstruera en teststorhet för fallet

	NF	F_b	F_g
T	0	0	X

$$\Theta^0 = \{[b, g] \mid g = 1\}$$

25

Minimering av $V(\theta, z)$

$$V(\theta, z) = \frac{1}{N} \sum_{t=1}^N \|y(t) - \hat{y}(t|\theta)\|^2$$

$$T(z) = \min_{\theta \in \Theta^0} V(\theta, z)$$

- generell optimering
- systemidentifiering
- minstakvadratmetoden
- observatörer, Kalman filter
- on-line vill man gärna ha rekursiva algoritmer
- ...

27

Exempel, forts.

Använd de generella formlerna:

$$T(z) = \min_{\theta \in \Theta^0} \frac{1}{N} \sum_{t=1}^N \|y(t) - \hat{y}(t|\theta, z)\|^2 = \min_b \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t|b, u))^2$$

$$\hat{y}(t|b, u) = u(t) + b$$

⇒

$$T(z) = \min_b \frac{1}{N} \sum_{t=1}^N (y(t) - u(t) - b)^2$$

Minimeringen är enkel

$$T(z) = \frac{1}{N} \sum_{t=1}^N (y(t) - u(t) - \hat{b})^2 \quad \text{där} \quad \hat{b} = \frac{1}{N} \sum_{t=1}^N (y(t) - u(t))$$

Notera att bias-felet har avkopplats i $T(z)$.

26

Linjär regression; minstakvadrat-metoden

Trevligt specialfall: Linjär regression ger analytisk lösning på optimeringen

$$y(t) = \varphi(t)\theta$$

Stapla N data ovanpå varandra, modellen blir då $Y = \Phi\theta$ där

$$\Phi = \begin{bmatrix} \varphi(1) \\ \vdots \\ \varphi(N) \end{bmatrix} \quad \text{och} \quad Y = \begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix}$$

Då kan teststorheten tecknas

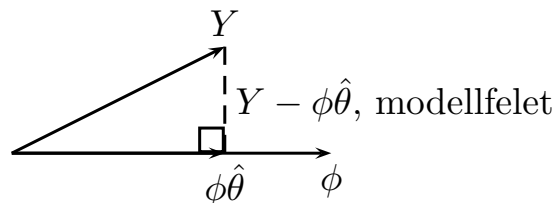
$$T(z) = \min_{\theta} \sum_{t=1}^N \|y(t) - \hat{y}(t|\theta)\|^2 = \min_{\theta} \|Y - \hat{Y}\|^2 = \min_{\theta} \|Y - \Phi\theta\|^2$$

28

$$T(z) = \min_{\theta} \|Y - \Phi\theta\|$$

Med N data är modellen $Y - \Phi\theta$ överbestämd och skattningen av θ som minimerar prediktionsfelet $\|Y - \Phi\theta\|$ ges av ett normalekvationen:

$$\Phi^T(Y - \Phi\hat{\theta}) = 0 \Leftrightarrow \text{ortogonalitet mellan modellprediktion och modellfel}$$



Givet excitation så ges ett unikt $\hat{\theta}$ av det analytiska uttrycket:

$$\begin{aligned} \hat{\theta} &= (\Phi^T\Phi)^{-1}\Phi^TY \quad \min_{\theta} \|Y - \Phi\theta\| = \|Y - \Phi\hat{\theta}\| = \\ &= (I - \Phi(\Phi^T\Phi)^{-1}\Phi^T)Y = P_r Y \end{aligned}$$

Numeriskt är detta inget bra sätt att faktiskt räkna ut skattningen. 29

Diskussionen runt excitation gäller generellt, men den är enkel att redovisa i fallet linjär regression.

Om vi inte har tillräcklig excitation så har ekvationen inte en unik lösning, men den har lösningar.

$$\Phi^T(Y - \Phi\hat{\theta}) = 0$$

- unik lösning eller inte, spelar det någon roll?
- algoritmen måste ta hänsyn
- kvalitet hos skattningen

För att ekvationen

$$\Phi^T(Y - \Phi\hat{\theta}) = 0$$

ska ge ha en unik lösning krävs att Φ måste ha full kolonnrang, dvs systemet måste exciteras.

Det spelar dock ingen roll för residualen

$$r = |Y - \hat{Y}| = |Y - \Phi\hat{\theta}|$$

vi använder ju inte värdet på skattningen. (Det finns alltid ett kortaste avstånd från en punkt till de plan som kolonnvektorerna i Φ spänner upp).

Stokastiska beskrivningar i modellen kan användas för att beräkna kvaliteten på skattningen av θ , typiskt ett variansmått. Mer om det senare.

Om man har en linjär regression

$$y_t = \varphi_t\theta$$

så finns det flera olika sätt att skatta parametern θ . Ett sätt har vi redan sett, att stapla N datapunkter på varandra och lösa ett minsta-kvadratproblem.

Ett sätt att få en rekursiv algoritmen är att beskriva parametern som en slumpvandring

$$\begin{aligned} \theta_{t+1} &= \theta_t + v_t \\ y_t &= \varphi_t\theta_t + \epsilon_t \end{aligned}$$

och applicera ett standard Kalman-filter. En enklare variant är Recursive Least Squares (RLS) som är ett specialfall av Kalmanfilter-lösningen ovan.

Mer generellt statistiskt fall

Är det kört om systemet inte är given som en linjär regression? Alls inte, bara lite svårare. Applicera någon metod för att skatta parametrar i olinjära modeller

$$y_t = g(\theta, z_t)$$

Ett enkelt sätt om man rekursivt vill följa parametern är att

$$\begin{aligned}\theta_{t+1} &= \theta_t + v_t \\ y_t &= g(\theta_t, z_t) + \epsilon_t\end{aligned}$$

och applicera favoriten bland olinjära tillståndsskattare. Exempelvis (Extended-) Kalman Filter, UKF, ...

Svårt att bevisa konvergens för godtyckliga olinjära funktioner $g(\theta, z)$ men standardmetoder kan ofta fungera mycket bra.

33

Exempel på EKF som residualgenerator

Antag modellen

$$\begin{aligned}x_{t+1} &= x_t - T_s \beta x_t + T_s u \\ y_t &= x_t + f_t\end{aligned}$$

där vi vill detektera fel f_t även då β varierar långsamt. Modellen under noll-hypotesen, med tillagt mät och processbrus, är

$$\begin{pmatrix} \beta_{t+1} \\ x_{t+1} \end{pmatrix} = \begin{pmatrix} \beta_t \\ x_t - T_s \beta_t x_t + T_s u \end{pmatrix} + w_t$$
$$y_t = x_t + e_t$$

35

Mer generella dynamiska fall då?

Mer generellt då, när det inte är en linjär regression? Antag att modellen under nollhypotesen ges av

$$\begin{aligned}\dot{x} &= g(x, u, \theta) \\ y &= h(x)\end{aligned}$$

Här kan man göra på samma sätt

$$\begin{aligned}\dot{\hat{x}}(t) &= g(\hat{x}(t), u(t), \hat{\theta}(t)) + K_1(y(t) - h(\hat{x}(t))) \\ \dot{\hat{\theta}}(t) &= 0 + K_2(y(t) - h(\hat{x}(t)))\end{aligned}$$

och konstruera teststorheten, exempelvis, som

$$T(t) = \int_{t-\Delta T}^t (y(\tau) - h(\hat{x}(\tau)))^2 d\tau$$

Ganska allmänt! Vi återkommer mer senare till observatörer, de är en mycket användbar metod att tillgripa som fungerar i många situationer.

34

Extended Kalman Filter

$$\begin{aligned}x_{t+1} &= g(x_t, w_t), & \text{cov } w_t &= Q_t \\ y_t &= h(x_t) + e_t, & \text{cov } e_t &= R_t\end{aligned}$$

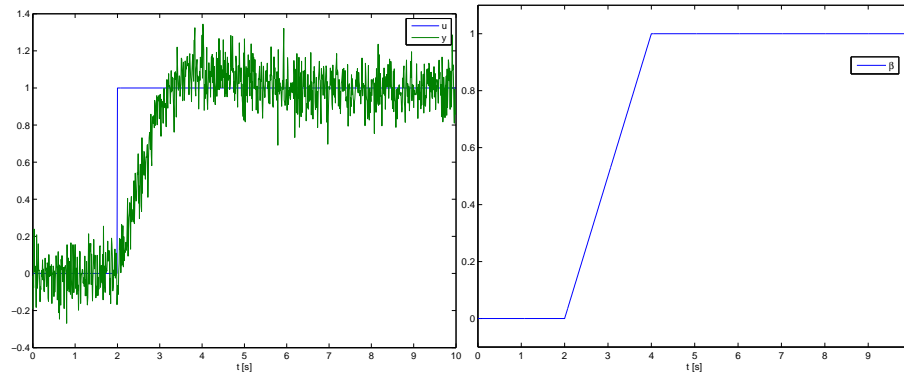
Mätuppdatering

$$\begin{aligned}\hat{x}_{t|t} &= \hat{x}_{t|t-1} + K_t(y_t - h(\hat{x}_{t|t-1})) & H_t &= \frac{\partial}{\partial x} h(x)|_{x=\hat{x}_{t|t-1}} \\ K_t &= P_{t|t-1} H_t^T (H_t P_{t|t-1} H_t^T + R_t)^{-1} \\ P_{t|t} &= P_{t|t-1} - K_t H_t P_{t|t-1}\end{aligned}$$

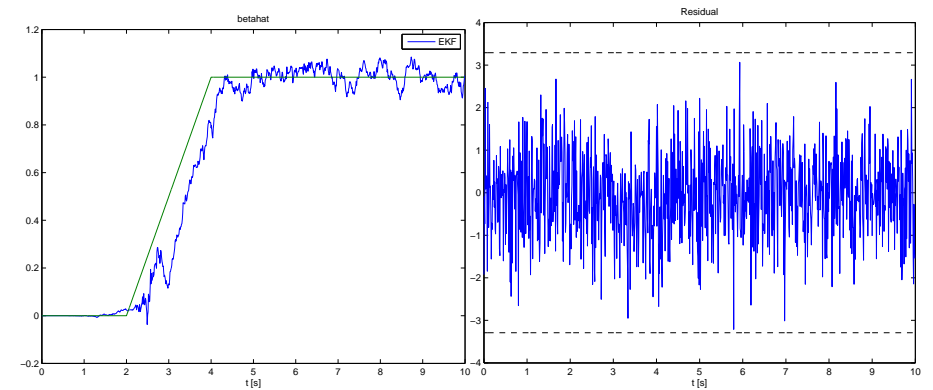
Tidsuppdatering

$$\begin{aligned}\hat{x}_{t+1|t} &= g(\hat{x}_{t|t}, 0) & F_t &= \frac{\partial}{\partial x} g(x, w)|_{x=\hat{x}_{t|t}, w=0} \\ P_{t+1|t} &= F_t P_{t|t} F_t^T + G_t Q_t G_t^T & G_t &= \frac{\partial}{\partial w} g(x, w)|_{x=\hat{x}_{t|t}, w=0}\end{aligned}$$

36



37



38

Översikt

- *Beteendemoder och beteendemodeller*
- *Teststorheten och modellvalidering*
- *Design av teststorheter*
 - *Prediktionsfel*
 - *Parameterskattningar*
 - *Likelihood-funktionen*
- *Avslutning*

39

Teststorheter baserade på parameterskattningar

Enkel idé: Om alla fel modelleras med avvikelser i konstanta parametrar θ_j , skatta alla parametrar och jämför med deras nominella värden. En vanlig ansats är då något i stil med

$$\hat{\theta} = \arg \min_{\theta} V(\theta, \text{observationer})$$

där $V(\theta, \text{observationer})$ är en modellvalideringsfunktion för hela modellen, inklusive alla felparametrar.

- Varför är detta inte alltid en attraktiv lösning?
- Metoden kräver unik lösning på minimeringen, dvs excitation.
- Storlek på felvektorn

40

Enkel idé: skatta ett element θ_i i feltillståndsvektorn θ och jämför med det nominella (dvs. felfria) värdet θ_i^0 .

Om mängden Θ^0 består av ett enda element:

$$T(\mathbf{x}) = \|\hat{\theta}_i - \theta_i^0\| \quad \hat{\theta}_i = \arg \min_{\theta_i} V'(\theta_i, \mathbf{x})$$

där $V'(\theta_i, \mathbf{x})$ är något modellvaliderings mått.

Hur blir det med isolering? Om det i verkligheten är ett fel i parameter θ_1 som inträffat, vad händer med skattningen av parameter θ_2 ?

Isolering blir lidande. När $\hat{\theta}_2$ avviker från sitt nominella värde, beror det på θ_2 eller någon annan förändring?

41

Exempel

$$y(t) = \theta_1 u_1(t) + \theta_2 u_2(t) + \theta_3 u_3(t)$$

$$H^0 : F_p \in \{NF, F_1\}$$

$$H^1 : F_p \in \{F_2, F_3\}$$

$$T = |\hat{\theta}_2 - \theta_2^0|$$

$$\hat{\theta}_2 = \arg_{\theta_2} \min_{\theta_1, \theta_2} \sum_{t=1}^N (y(t) - \theta_1 u_1(t) - \theta_2 u_2(t) - \theta_3 u_3(t))^2$$

Minimeringen kan lösas med linjär regression. Teststorheten kan också beräknas rekursivt.

43

	F_1	F_2	F_3
T_1	0	X	X
T_2	X	0	X
T_3	X	X	0

För till exempel test T_1 skulle man då kunna göra

$$T_1 = |\hat{\theta}_2 - \theta_2^{nom}|$$

där

$$\hat{\theta}_2 = \arg \min_{\theta_2} V(\theta_1, \theta_2, \text{observationer})$$

Som synes måste man skatta minst två parametrar, dels variabeln vi vill avkoppla, dels variabeln vi vill jämföra mot sitt nominella värde.

42

Översikt

- *Beteendemoder och beteendemodeller*
- *Teststorheten och modellvalidering*
- *Design av teststorheter*
 - *Prediktionsfel*
 - *Parameterskattningar*
 - *Likelihood-funktionen*
- *Avslutning*

44

Teststorhet baserad på likelihood-funktionen

Definition (Likelihood Function)

Let $f(\mathbf{z}|\theta)$ denote the probability density function of the sample $\mathbf{Z} = [Z_1, Z_2, \dots, Z_n]$. Then, given that $\mathbf{Z} = \mathbf{z}$ is observed, the function of θ defined by

$$L(\theta|\mathbf{z}) = f(\mathbf{z}|\theta)$$

is called the **likelihood function**.

En teststorhet kan formas som:

$$T(\mathbf{z}) = \max_{\theta \in \Theta^0} L(\theta|\mathbf{z})$$

Notera: likelihood-funktionen är en funktion av θ medans täthetsfunktionen är en funktion av \mathbf{z} .

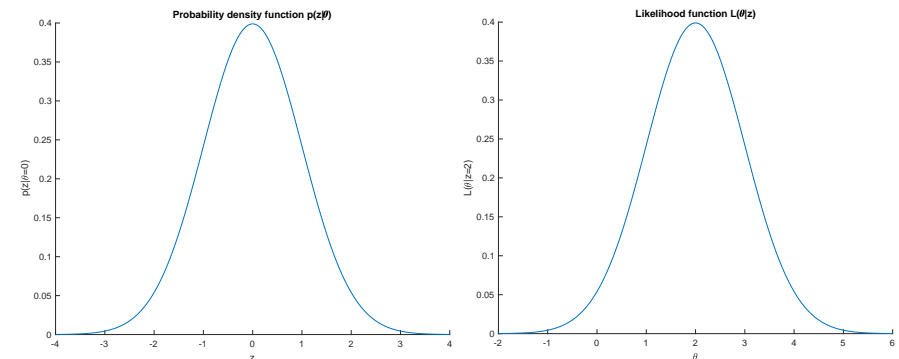
Tolkning: Hur sannolikt är det att observera det utfall vi observerat.

45

Likelihood-funktionen, normalfördelning, 1 observation

Modell: $Z \sim N(\theta, 1)$

En observation: $z = 2$



Täthetsfunktionen
 $f(z|\theta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(z-\theta)^2}{2}}$

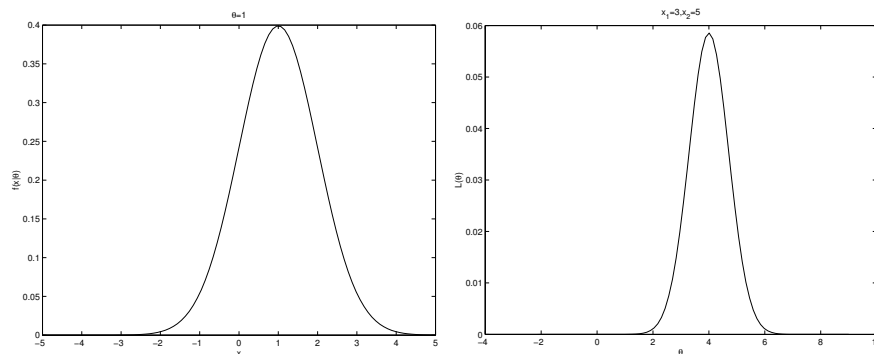
Likelihood-funktionen
 $L(\theta|z=2) = f(2|\theta)$

46

Likelihood-funktionen, normalfördelning, 2 observationer

Modell: $Z \sim N(\theta, 1)$

Två oberoende observationer: $z_1 = 3, z_2 = 5$



Täthetsfunktionen
 $f(z_i|\theta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(z_i-\theta)^2}{2}}$

Likelihood-funktionen
 $L(\theta|z_1 = 3, z_2 = 5) = f(3|\theta)f(5|\theta)$

47

Teststorheter baserade på likelihood-funktionen, forts.

Likelihood-funktionen säger (\approx) hur sannolikt det är att observera det utfall vi observerat. Därför bildas teststorheten genom att maximera

$$T(\mathbf{z}) = \max_{\theta \in \Theta^0} L(\theta|\mathbf{z})$$

istället för att minimera. Detta kallas **maximum-likelihood (ML)**. Nollhypotesen kommer därför att förkastas om $T(\mathbf{z})$ är **mindre** än en tröskel.

Man kan använda likelihood-funktionen för att skatta parametrar. ML-skattningen fås som:

$$\theta_{ML} = \arg \max_{\theta} L(\theta)$$

Mycket vanligt sätt att bilda teststorheter då man har statistiska modeller. Vi kommer återkomma till ML i avsnittet om "Change detection".

48

Om man räknar ut

$$T(\mathbf{z}) = \max_{\theta \in \Theta^0} L(\theta|\mathbf{z})$$

med $H_0 : F_p = F_i$ så har man samtidigt räknat ut

$$\max_{\theta \in \Theta^0} L(\theta|\mathbf{z}) = \max_{\theta \in \Theta^0} f(\mathbf{z}|\theta) = P(\mathbf{z}|F_i)$$

Om man har en a-priori sannolikhet för de olika felmoderna så kan man via Bayes sats göra omskrivningen

$$P(F_i|\mathbf{z}) = \frac{P(\mathbf{z}|F_i)P(F_i)}{P(\mathbf{z})}$$

Genom att beräkna sannolikheten för alla felmoder F_i så får vi en ranking av felen baserad på dess sannolikheter.

Mer om detta senare i kursen.

49

Översikt

- *Beteendemoder och beteendemodeller*
- *Teststorheten och modellvalidering*
- *Design av teststorheter*
 - *Prediktionsfel*
 - *Parameterskattningar*
 - *Likelihood-funktionen*
- *Avslutning*

51

Antag hypoteserna

$$H^0 : \theta = \theta_0$$

$$H^1 : \theta = \theta_1$$

där pdf för observationerna är den kända fördelningsfunktionen $f(\mathbf{z}|\theta_i)$ i de två fallen.

En lite "slarvig" formulering av Neyman-Pearson lemma är då:

Den bästa tänkbara teststorheten för dessa hypoteser är

$$T(\mathbf{z}) = \frac{f(\mathbf{z}|\theta_1)}{f(\mathbf{z}|\theta_0)}$$

Finns generaliserade resultat för nollhypoteser som inte är singeltons.

Mer om detta senare i kursen.

50

Teststorheter

- En teststorhet är ett modellvalideringsmått
- 4 allmänna principer för att konstruera teststorheter
 - 1 prediktionsfel
 - 2 parameterskattning
 - 3 likelihood-funktionen
 - 4 residualer, konsistensrelationer och observatörer
- Ej ortogonala och inga principer för när och hur.

Nästa gång: Tröskelsättning och försöka svara på frågan, hur bra är ett specifikt test?

52

TSFS06 Diagnos och övervakning
Föreläsning 5 - Konstruktion av teststorheter

Erik Frisk

Institutionen för systemteknik
Linköpings universitet
frisk@isy.liu.se

2017-04-05