

TSFS06 Diagnos och övervakning

Föreläsning 5 - Konstruktion av teststorheter

Erik Frisk

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

2019-04-08

1

Översikt

- *Beteendemoder, beteendemodeller, 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
 - 1 prediktionsfel
 - 2 residualer, konsistensrelationer och observatörer
 - 3 parameterskattning
 - 4 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

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:

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

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

5

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:

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

7

Teststorheten är ett modellvalideringsmått

Test T svarar alltså mot hypotestestet:

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

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

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

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

6

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

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

8

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

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

$$= \sum_{t=1}^N (y(t) - \hat{\theta}_1 u_1(t) - u_2(t) - u_3(t))^2$$

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.

9

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:

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

$$= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N ((1 - \theta_1) u_1(t) - (1 - \theta_2^1) u_2(t))^2$$

Låt

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

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

Då blir

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

11

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:

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

$$= \min_{\theta_1 \in \mathbb{R}} \sum_{t=1}^N (\theta_1^0 - \theta_1)^2 u_1(t)^2 = \int u_1(t) \equiv 0 \vee \hat{\theta}_1 = \theta_1^0 / 0 = 0$$

Modellen överensstämmer och måttet blir 0 då H_0 sann.


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

10

Modellvalideringsmått, forts.

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

Geometrisk tolkning:



$$T = \Delta^2$$

Fel F_2 detekteras om U_2 ej är parallell med U_1 .

12

Modell under nollhypotesen

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

Antag en modell:

$$\dot{x}_1 = g_1(x_1, x_2, f_1, u)$$

$$\dot{x}_2 = g_2(x_1, x_2)$$

$$\dot{f}_1 = 0$$

$$y_1 = h_1(x_1) + f_2$$

$$y_2 = h_2(x_2) + f_3$$

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

13

Modell under nollhypotesen, forts.

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

$$\dot{x}_1 = g_1(x_1, x_2, 0, u)$$

$$\dot{x}_2 = g_2(x_1, x_2)$$

$$y_1 = h_1(x_1)$$

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

15

Modell under nollhypotesen, forts.

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

$$\dot{x}_1 = g_1(x_1, x_2, f_1, u)$$

$$\dot{x}_2 = g_2(x_1, x_2)$$

$$\dot{f}_1 = 0$$

$$y_1 = h_1(x_1)$$

$$y_2 = h_2(x_2)$$

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 .

14

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.

16

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.

17

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.

19

- *Beteendemoder, beteendemodeller, och modellvalidering*

- *Design av teststorheter*
 - *Prediktionsfel*
 - *Parameterskattningar*
 - *Likelihood-funktionen*

- *Avslutning*

18

Principer för konstruktion av teststorheter

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.

20

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

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

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

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

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:

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

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

Om Θ^0 är en mängd av flera värden:

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

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

Notera: avkoppling

- *Beteendemoder, beteendemodeller, och modellvalidering*

- *Design av teststorheter*

- *Prediktionsfel*
- *Parameterskattningar*
- *Likelihood-funktionen*

- *Avslutning*

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

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

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 $T(z)$.

25

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

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

27

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
- ...


26

Linjär regression; minstakvadrat-metoden

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

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

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



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

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

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

28

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.

29

Linjär regression - rekursiv lösare

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 algoritm 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.

31

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?
- algoritm måste ta hänsyn
- kvalitet hos skattningen

30

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.

32

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.

33

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

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

35

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


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

34

EKF som residualgenerator



36



37

Teststorheter baserade på parameterskattningar

Enkel idé: Om alla fel modelleras med avvikelser i konstanta parametrar θ_i , 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

39

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

38

Teststorheter baserade på parameterskattningar

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?

40

	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

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

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



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

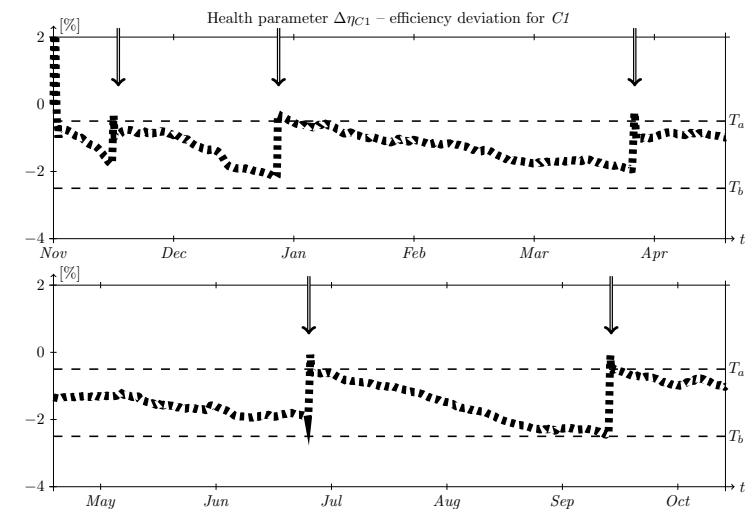
$$H^0 : F_p \in \{NF, F_1\}$$

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

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

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

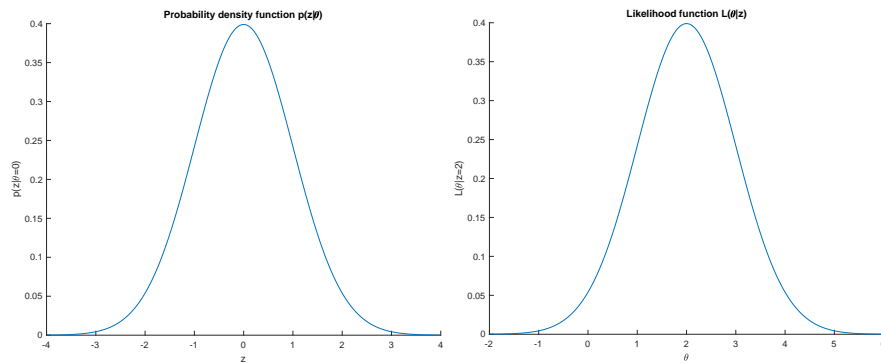
Minimeringen kan lösas med linjär regression. Teststorheten kan också beräknas rekursivt.



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

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
 $L(\theta|z = 2) = f(2|\theta)$

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.

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

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".

49

Neyman-Pearson lemma, likelihood-kvot

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.

51

Likelihood och Bayes

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.

50

Översikt

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

52

- 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?

TSFS06 Diagnos och övervakning

Föreläsning 5 - Konstruktion av teststorheter

Erik Frisk

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

2019-04-08