

Parameterskattning i linjära dynamiska modeller

Kap 12

Grundläggande ansats

- Antag (samplade) mätdata (y och u)från ett system har insamlats.
- Givet en modell $\mathcal{M}(t, \theta)$ och mätdata , hitta det θ som ger en så bra (i mistakvadratfelsmening) **prediktion** av systemet som möjligt.
”Prediktionsfelsminimering”.
Behöver konstruera en prediktor från modellen $\mathcal{M}(t, \theta)$, hur den ser ut beror på hur bruset modelleras.

Beteckning:

$\hat{y}(t|\theta)$ = prediktion av $y(t)$ givet data upp till $t - 1$.

- Skräddarsydda modeller (Grey-box modeller):
Skatta systemparametrar i fysikalisk modell.
- Konfektionsmodeller (Black-box modeller):
Parametrar har generellt ingen fysikalisk tolkning.
Typisk skattas parametrar i en “allmän” differensekvation.

Skräddarsydda modeller (12.1)

- Modellera okända parametrar i fysikalisk modell med parameter θ :

$$\dot{x}(t) = f(x(t), u(t), \theta)$$

$$y(t) = h(x(t), u(t), \theta)$$

- Använd mätningar till att skatta θ .
Tillvägagångssätt problemberoende.
- Mera om skräddarsydda modeller senare i kursen.

Linjära konfektionsmodeller (12.2)

- Olika klasser av konfektionsmodeller med störterm $w(t)$ och störningsfri insignal $\eta(t)$:

$$y(t) = \eta(t) + w(t)$$

- Box-Jenkins

$$\begin{aligned} y(t) &= G(q, \theta)u(t) + H(q, \theta)e(t) \\ G(q, \theta) &= \frac{B(q)}{F(q)} \\ &= \frac{b_1 q^{-nk} + \dots + b_{nb} q^{-nk-nb+1}}{1 + f_1 q^{-1} + \dots + f_{nf} q^{-nf}} \\ H(q, \theta) &= \frac{C(q)}{D(q)} = \frac{1 + c_1 q^{-1} + \dots + c_{nc} q^{-nc}}{1 + d_1 q^{-1} + \dots + d_{nd} q^{-nd}} \end{aligned}$$

där $e(t)$ =vitt brus. Notera att insignalen $u(k)$ är tidsfördröjd nk sampel.

- Output-Error (OE). Modellerar ej störsignalens egenskaper.

$$y(t) = G(q, \theta)u(t) + e(t)$$

- FIR (specialfall av OE):

$$y(t) = B(q)u(t) + e(t)$$

- ARMAX. Antar $F(q) = D(q) = A(q)$:

$$A(q)y(t) = B(q)u(t) + C(q)e(t)$$

- **ARX**. Sätt $C(q) = 1$ i ARMAX modellen:

$$A(q)y(t) = B(q)u(t) + e(t)$$

Även rena tidsseriemodeller (bara en signal y) kan erhållas:

- ARMA ($B = F = 0$):

$$A(q)y(t) = C(q)e(t)$$

$C(q) = 1$ ger AR, $A(q) = 1$ ger MA.

- Modellerna används på så sätt att man anger ordningstalen na, nb, nc, nd, nf och nk och beräknar de parametrar som bäst beskriver data.
- Val av modell mm i Kap 14.

Anpassning av modeller till data (12.3)

- Givet en parametrisk modell och gamla mätdata $\{y(s), u(s)\}_{s=\leq t-1}$ kan man prediktera värdet på utsignalen vid tiden t . Prediktionen betecknas $\hat{y}(t|\theta)$.
- Prediktionsfelet definieras som:

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

- Ide: Välj den modell θ som minimerar prediktionsfelens varians.

- \Rightarrow Givet mätdata $\{y(t), u(t)\}_{t=1,\dots,N}$ bilda förlustfunktionen:

$$V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \epsilon^2(t, \theta)$$

och beräkna det θ som minimierar $V_N(\theta)$:

$$\hat{\theta}_N = \arg \min_{\theta} V_N(\theta)$$

- Om störningarna är Gaussiska så är ovanstående maximum-likelihood (ML) skatningen av θ .

Prediktion

- Prediktor för generell modell (Box-Jenkins):

$$\hat{y}(t|\theta) = [1 - H^{-1}(q, \theta)]y(t) + H^{-1}(q, \theta)G(q, \theta)u(t)$$

- Prediktor för Output-error modell:

$$\hat{y}(t|\theta) = \frac{B(q, \theta)}{A(q, \theta)}u(t)$$

- Prediktor för ARX-modell:

$$\hat{y}(t|\theta) = [1 - A(q, \theta)]y(t) + B(q, \theta)u(t)$$

Linjär regression - jmfr F2!

- Minimeringen av förlustfunktionen är speciellt enkel om prediktionen kan skrivas som en linjär funktion av θ .
- För en ARX modell kan prediktionen skrivas som:

$$\hat{y}(t|\theta) = \theta^T \varphi(t)$$

där

$$\begin{aligned}\theta &= [a_1 \cdots a_{na} \ b_1 \cdots b_{nb}]^T \\ \varphi(t) &= [-y(t-1) \cdots -y(t-na) \\ &\quad u(t-nk) \cdots u(t-nk-nb+1)]^T\end{aligned}$$

- Motsvarande prediktionsfel blir:

$$\epsilon(t, \theta) = y(t) - \theta^T \varphi(t)$$

- Förlustfunktionen $V_N(\theta)$ minimimeras i detta fall av:

$$\hat{\theta}_N = R_N^{-1} f_N$$

där

$$\begin{aligned} f_N &= \frac{1}{N} \sum_{t=1}^N \varphi(t) y(t) \\ R_N &= \frac{1}{N} \sum_{t=1}^N \varphi(t) \varphi^T(t) \end{aligned}$$

- Notera att (för ARX modellen) består elementen i f_N och R_N alla av skattningar av olika kovariansfunktioner för y och u .
- Vid beräkning av skattningen skall invertering av R_N undvikas av numeriska skäl.

Iterativ sökning

- För många modellstrukturer (B-J, OE, ARMAX...) är funktionen $V_N(\theta)$ en komplicerad funktion av θ . Då måste numerisk sökning användas.

Ex: Newton-Raphsons metod:

$$\hat{\theta}^{(i+1)} = \hat{\theta}^{(i)} - \mu_i [V_N''(\hat{\theta}^{(i)})]^{-1} V_N'(\hat{\theta}^{(i)})$$

Se boken (289-290) för detaljer.

- Det finns färdiga rutiner i Matlab som gör minimeringen.
`theta='metod' (data,modellordning)` men även ett grafiskt gränssnitt (Blabb 2)

Modellens egenskaper (12.4)

- Hur bra blir modellskattningar med prediktionsfelsmetoden?
- Modellens **variansfel** beror på att mätningarna och systemet påverkas av brus. Identiska experiment ger aldrig likadana resultat.
- Modellens **biasfel** beror på att modellen ej fullständigt kan beskriva systemet. Biasfelet kavarstår även om mätningarna skulle kunna göras utan inverkan av brus.
- En bra modell har både litet variansfel och biasfel.

Biasfelet

Antag ett sannt system

$$y(t) = G_o(q)u(t) + w(t)$$

samt en linjär modell med θ -oberoende brusmodell

$$y(t) = G(q, \theta)u(t) + H_*(q)e(t)$$

då gäller

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

Variansfelet

- Antag att biasfelet = 0. Då gäller:

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

där

$$\begin{aligned}\bar{R} &= E\Psi(t, \theta_0)\Psi(t, \theta_0)^T \\ \Psi(t, \theta_0) &= \frac{d}{d\theta}\hat{y}(t|\theta)\end{aligned}$$

- OBS. För ARX modell är $\Psi(t, \theta_0) = \varphi(t)$
- Formell beskrivning (sid 299):

$$\sqrt{N}(\hat{\theta}_N - \theta_0) \in AsN(0, \lambda \bar{R}^{-1})$$

- Konfidensintervall för den skattade modellen kan beräknas!
- I frekvensplanet gäller approximativt:

$$\text{var}(G(e^{i\omega}, \hat{\theta}_N)) \approx \frac{n}{N} \frac{\Phi_w(\omega)}{\Phi_u(\omega)}$$

där n är modellens ordningstal. Notera att biasfelet antas vara noll.

Identifierbarhet

- Olika värden på θ bör ge olika prediktioner $\hat{y}(t, \theta)$.
- Identifierbarhet: parametrarna kan bestämas från mätdata.
- Icke-identifierbarhet kan bero på:
 - Parametriseringen
 - Insignalen
 - Återkoppling