

Méréselmélet

7. fejezet: Modellalapú jelfeldolgozás (folyt.)


Összefoglalás

2022. május 18.

Paramétereiket/struktúrájukat változtató, ún. variáns rendszerek: adaptív/hangolható/átkapcsolható... Átkapcsolások tranziens jelenségeinek struktúrafüggése


Kis sávszélességű merőcsatornával mérünk a kellő zajelnyomás érdekében. Kis sávszélesség esetében a beállítás lassú.

Gyorsítsuk a beállást úgy, hogy a bekapcsolást követően egy ideig nagyobb sávszélességet biztosítunk, majd keskenyebbé váltunk!



Az egyszerűség kedvéért a jelenségeket elsőfokú aluláteresztő szűrőkkel demonstráljuk.

A megvalósítandó átviteli függvény: $H(z) = \frac{a_1 z^{-1}}{1 - b_1 z^{-1}}$
 amelynek átvitele a 0 frekvencián $H(0) = \frac{a_1}{1 - b_1} = 1$,
 ahonnan $a_1 = 1 - b_1$. A nagyobb sávszélesség esetén legyen $b_1 = 0.5$,
 a kisebb sávszélesség esetén pedig $b'_1 = 0.8$.




A váltás eredménye!
 Ezzel $a_1 = 0.5$, ill. $a'_1 = 0.2$ jár.

A rezonátoros struktúra esetén célszerűen $z_0 = 1$ választással:

$$H(z) = \frac{r_0 z^{-1}}{1 + \frac{r_0 z^{-1}}{1 - z^{-1}}} = \frac{r_0 z^{-1}}{1 - (1 - r_0)z^{-1}} w_0 = \frac{a_1 z^{-1}}{1 - b_1 z^{-1}}$$


Innen $w_0 = 1$, $r_0 = 1 - b_1$, ill. $r_0 = a_1 = 0.5$, és $r'_0 = a'_1 = 0.2$. $y(n) = a_1 u(n - 1) + b_1 y(n - 1)$



válasz	direkt struktúra	rezonátoros struktúra	válasz	gyors	lassú	válasz	direkt	rezon.
$y(0)$	0	0	$y(0)$	0	0	$y(0)$	0	0
$y(1)$	a_1	r_0	$y(1)$	0.5	0.2	$y(1)$	0.5	0.5
$y(2)$	$a_1(1 + b_1)$	$r_0 + (1 - r_0)r_0$	$y(2)$	0.75	0.36	$y'(2)$	0.3	0.75
$y(3)$	$a_1(1 + b_1 + b_1^2)$	$r_0 + (1 - r_0)r_0 + (1 - r_0)^2 r_0$	$y(3)$	0.875	0.488	$y'(3)$	0.44	0.8
$y(4)$	$a_1(1 + b_1 + b_1^2 + b_1^3)$	$r_0 + (1 - r_0)r_0 + (1 - r_0)^2 r_0 + (1 - r_0)^3 r_0$	$y(4)$	0.9375	0.5904	$y'(4)$	0.552	0.84
$y(n)$	$a_1(1 + b_1 + \dots + b_1^{n-1}) = a_1 \frac{1 - b_1^n}{1 - b_1}$	$r_0(1 + (1 - r_0) + \dots + (1 - r_0)^{n-1}) = 1 - (1 - r_0)^n$	$y(n)$	$\rightarrow 1$	$\rightarrow 1$	$y(n)$	$\rightarrow 1$	$\rightarrow 1$


Ebben a példában a transzponált direkt struktúra is jól viselkedik!

Passzivitás az irányítástechnikában: szabályozás hálózaton keresztül



$$\int_0^t P_{in}(\tau) d\tau = \int_0^t u_d(\tau)y(\tau) d\tau \geq 0 \quad \forall t > 0$$

A hálózat késleltetése a szabályzó tervezés hagyományos módszereinek alkalmazását nem teszi lehetővé. Ún. passzíváló transzformációt vezetünk be annak érdekében, hogy a szabályzó által látott szakasz passzív maradjon.



$$\begin{bmatrix} u_1(t) \\ y_2(t) \end{bmatrix} = T^{-1} \begin{bmatrix} u(t) \\ y_d(t) \end{bmatrix} \quad \begin{bmatrix} u_d(t) \\ y(t) \end{bmatrix} = T \begin{bmatrix} u_2(t) \\ y_1(t) \end{bmatrix}$$

$$V_N(t) = \int_0^t [(u_1^T(\tau)u_1(\tau) + y_1^T(\tau)y_1(\tau) - u_2^T(\tau)u_2(\tau) - y_2^T(\tau)y_2(\tau))] d\tau$$

Mivel a hálózatban tárolt energia nemnegatív, a kontroller oldalán a bevitt és kivett energia különbsége \geq mint a hálózatból továbbküldött, ill. befogadott energiák különbsége:

$$\int_0^t [(u_1^T(\tau)u_1(\tau) - y_2^T(\tau)y_2(\tau))] d\tau \geq \int_0^t [u_2^T(\tau)u_2(\tau) - y_1^T(\tau)y_1(\tau)] d\tau$$

A hálózatba bevitt energia A hálózatból kivett energia
 $V_N(t) = \int_{t-T_1}^t u_1^T(\tau)u_1(\tau) d\tau + \int_{t-T_2}^t y_1^T(\tau)y_1(\tau) d\tau \geq 0 \quad \forall t$ -re.

$$\int_0^t (u_d^T(\tau)y(\tau)) d\tau = \int_0^t [u_2^T(\tau)u_2(\tau) - y_1^T(\tau)y_1(\tau)] d\tau$$

A **P** szakasz transzformált + a hálózat belső energiája

A **P** szakasz transzformált belső energiája

$$\int_0^t u^T(\tau)y_d(\tau) d\tau = \int_0^t [u_1^T(\tau)u_1(\tau) - y_2^T(\tau)y_2(\tau)] d\tau$$

Keresett az a transzformáció, amely a P folyamat belső energiáját a megadott formába transzformálja:

$$\begin{bmatrix} u_d(t) \\ y(t) \end{bmatrix} = \begin{bmatrix} t_{00} & t_{01} \\ t_{10} & t_{11} \end{bmatrix} \begin{bmatrix} u_2(t) \\ y_1(t) \end{bmatrix} \quad \int_0^t (u_d^T(\tau)y(\tau) d\tau = \int_0^t [u_2^T(\tau)u_2(\tau) - y_1^T(\tau)y_1(\tau)]d\tau$$

Egy lehetséges megoldás: $\begin{bmatrix} u_d(t) \\ y(t) \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} u_2(t) \\ y_1(t) \end{bmatrix}$

Keresett az a transzformáció, amely a P folyamat transzformált + a hálózat belső energiáját a megadott formába transzformálja:

$$\begin{bmatrix} u(t) \\ y_d(t) \end{bmatrix} = \begin{bmatrix} t_{00} & t_{01} \\ t_{10} & t_{11} \end{bmatrix} \begin{bmatrix} u_1(t) \\ y_2(t) \end{bmatrix} \quad \int_0^t u^T(\tau)y_d(\tau) d\tau = \int_0^t [u_1^T(\tau)u_1(\tau) - y_2^T(\tau)y_2(\tau)]d\tau$$

$\begin{bmatrix} u(t) \\ y_d(t) \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} u_1(t) \\ y_2(t) \end{bmatrix}$


A hozzátartozó Implementáció:

$$\begin{bmatrix} u_d(t) \\ y_1(t) \end{bmatrix} = \begin{bmatrix} 2 & -1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} u_2(t) \\ y_2(t) \end{bmatrix}$$

$$\begin{bmatrix} u_1(t) \\ y_d(t) \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ 1 & -2 \end{bmatrix} \begin{bmatrix} u(t) \\ y_1(t) \end{bmatrix}$$

Megjegyzés: $\begin{bmatrix} u_d(t) \\ y(t) \end{bmatrix} = T \begin{bmatrix} u_2(t) \\ y_1(t) \end{bmatrix} = \begin{bmatrix} 1 & a \\ 1 & -a \end{bmatrix} \begin{bmatrix} u_2(t) \\ y_1(t) \end{bmatrix},$

$$\begin{bmatrix} u(t) \\ y_d(t) \end{bmatrix} = T \begin{bmatrix} u_1(t) \\ y_2(t) \end{bmatrix} = \begin{bmatrix} 1 & a \\ 1 & -a \end{bmatrix} \begin{bmatrix} u_1(t) \\ y_2(t) \end{bmatrix}$$



$$0 < |a| \leq 1$$

$$\begin{bmatrix} u_d(t) \\ y_1(t) \end{bmatrix} = \begin{bmatrix} 2 & -1 \\ 1/a & -1/a \end{bmatrix} \begin{bmatrix} u_2(t) \\ y_2(t) \end{bmatrix},$$

$$\begin{bmatrix} u_1(t) \\ y_d(t) \end{bmatrix} = \begin{bmatrix} 1 & -a \\ 1 & -2a \end{bmatrix} \begin{bmatrix} u(t) \\ y_1(t) \end{bmatrix}$$

$P(s)$ helyett:

$$P_2(s) = \frac{1 - K(s) + P(s)(1 + K(s))}{1 + K(s) + P(s)(1 - K(s))}$$

$$P_1(s) = 1 - 2 \frac{P(s)}{1 + P(s)}$$

De: $P_2(s)$ passzív tetszőleges készletetésre, ha P az.

Vissza a transzformációkhoz: Ortogonális transzformáció adatredukciós céllal

Főkomponens analízis/Karhunen-Loève transzformáció:

Célunk az utóbbi dimenziójának csökkentése átlagos négyzetes kritérium szerint optimálisan.

$$\mathbf{x} = \mathbf{T}\mathbf{y}, \quad \mathbf{T}^T = [\boldsymbol{\phi}_0 \quad \boldsymbol{\phi}_1 \quad \dots \quad \boldsymbol{\phi}_{N-1}], \quad \boldsymbol{\phi}_i^T \boldsymbol{\phi}_j = \delta_{ij}$$

$$\mathbf{y} = \mathbf{T}^T \mathbf{x} = \sum_{i=0}^{N-1} x_i \boldsymbol{\phi}_i, \quad \hat{\mathbf{y}} = \sum_{i=0}^{M-1} x_i \boldsymbol{\phi}_i + \sum_{i=M}^{N-1} b_i \boldsymbol{\phi}_i$$

$$\Delta \mathbf{y} = \mathbf{y} - \hat{\mathbf{y}} = \sum_{i=M}^{N-1} (x_i - b_i) \boldsymbol{\phi}_i$$

Az átlagos négyzetes hiba:

Az eddigi jelöléseket alkalmazzuk. A reprezentálandó jel mintáit az \mathbf{y} a reprezentáló értékeket pedig az \mathbf{x} vektorba rendezzük.

Ehhez egy ortogonális bázis-reciprok bázis rendszert keresünk a jelhez:

Az \mathbf{y} reprezentációja a teljes, ill. a redukált rendszerben:

Látható, hogy $M < N$ számú együtthatóval akarjuk reprezentálni a jelet, a maradék $N - M$ bázisvektor súlytényezőjét pedig hibaminimalizálással határozzuk meg. A közelítés hibája:

$$\varepsilon = E\{|\Delta \mathbf{y}|^2\} = E\{(\Delta \mathbf{y})^T \Delta \mathbf{y}\} = \sum_{i=M}^{N-1} E\{(x_i - b_i)^2\}.$$

Első lépésben keressük a minimális hibát okozó b_i tényezőket! Deriválás után: $b_i = E\{x_i\}, i = M, M + 1, \dots, N - 1.$

Mivel $x_i = \boldsymbol{\phi}_i^T \mathbf{y}$, ezért $b_i = \boldsymbol{\phi}_i^T E\{\mathbf{y}\} = \boldsymbol{\phi}_i^T \bar{\mathbf{y}}$, amit behelyettesítve a hiba összefüggésébe:

$$\varepsilon = \sum_{i=M}^{N-1} \boldsymbol{\phi}_i^T E\{(\mathbf{y} - \bar{\mathbf{y}})(\mathbf{y} - \bar{\mathbf{y}})^T\} \boldsymbol{\phi}_i = \sum_{i=M}^{N-1} \boldsymbol{\phi}_i^T \mathbf{C}_{yy} \boldsymbol{\phi}_i$$

Második lépésként keressük azt a $\boldsymbol{\phi}_i, i = 0, 1, \dots, N - 1$ bázisrendszert, amelyre $\boldsymbol{\phi}_i^T \boldsymbol{\phi}_i = 1$, és a hibát minimalizálja. Ehhez a feltételes szélsőérték kereséshez a Lagrange multiplikátoros módszert alkalmazzuk:

ahol \mathbf{C}_{yy} a reprezentálandó jel kovariancia mátrixa.

$$\hat{\varepsilon} = \varepsilon - \sum_{i=M}^{N-1} \beta_i [\boldsymbol{\phi}_i^T \boldsymbol{\phi}_i - 1] = \sum_{i=M}^{N-1} [\boldsymbol{\phi}_i^T \mathbf{C}_{yy} \boldsymbol{\phi}_i - \beta_i [\boldsymbol{\phi}_i^T \boldsymbol{\phi}_i - 1]], \quad \beta_i, i = M, M + 1, \dots, N - 1, \text{ a Lagrange multiplikátor.}$$

Deriválunk $\boldsymbol{\phi}_i$ szerint: $\frac{\partial \hat{\varepsilon}}{\partial \boldsymbol{\phi}_i} = 2\mathbf{C}_{yy} \boldsymbol{\phi}_i - 2\beta_i \boldsymbol{\phi}_i = \mathbf{0}$ ahonnan: $\mathbf{C}_{yy} \boldsymbol{\phi}_i = \beta_i \boldsymbol{\phi}_i$, azaz a Lagrange multiplikátorok az \mathbf{y} vektor \mathbf{C}_{yy} kovariancia mátrixának alkalmas sajátértékei.

Ezt visszahelyettesítve $\varepsilon_{min} = \sum_{i=M}^{N-1} \beta_i$,

azaz az átlagos négyzetes értelemben legkisebb közelítési hiba eléréséhez bázisvektorokként az \mathbf{y} kovariancia mátrixának sajátvektorai közül azt a M ún. főkomponenst kell kiválasztani, amelyhez az M legnagyobb sajátérték tartozik.

Méréselmélet mindössze 5 oldalon!

Összefoglalás és üzenetek:



Megfigyelő elmélet alapú tárgyalás

Lehetőleg rekurzív/valós idejű kiértékelés



Hatékony megvalósítás (műszertechnika)

1. Bevezetés




A mérés minőségét egyrészt annak **pontosságával** (accuracy) jellemezzük, azaz milyen közel van a mért érték a helyes (elméleti) értékhez, másrészt a mért értékek **„együttfutásával”** (precision), azaz avval, hogy milyen közel vannak egymáshoz a mért értékek.




2. Döntésemélet alapjai




Véletlen folyamatok



3. Becslésmélet alapjai



3.1. Bayes becslések:



3.1.1. Minimális átlagos négyzetes hibájú becslő:

$$\hat{a}_{MS} = \int_{-\infty}^{\infty} af(a|z)da,$$

3.1.2. Minimális átlagos abszolút hibájú becslő:

$\hat{a}_{ABS} = f(a|z)$ mediánja.

3.1.3. Maximum a posteriori (MAP) becslés:

$\hat{a}_{MAP} = f(a|z)$ maximumhelye

$$\hat{a}_{MS} = \mu_{a|z} = \underbrace{\mu_a}_{\text{apriori ismeret}} + \underbrace{[U^T \Sigma_{nn}^{-1} U + \Sigma_{aa}^{-1}]^{-1} U^T \Sigma_{nn}^{-1} (z - U \mu_a)}_{\text{korrekció } z-U\mu_a \text{ függvényében}}$$

$$cov\{a, a|z\} = \Sigma_{aa|z} = [U^T \Sigma_{nn}^{-1} U + \Sigma_{aa}^{-1}]^{-1}$$

3.2. Maximum Likelihood (ML) becslő:

$$\left. \frac{\partial f(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = 0, \text{ vagy } \left. \frac{\partial \ln f(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = 0, \quad \hat{a}_{GM} = [U^T \Sigma_{nn}^{-1} U]^{-1} U^T \Sigma_{nn}^{-1} z,$$

3.3. Becslők determinisztikus paraméterek esetén:

$mse(\hat{a}) = E\{[\hat{a} - E[\hat{a}] + E[\hat{a}] - a]^2\} = E\{[\hat{a} - E[\hat{a}] + b(a)]^2\} = var(\hat{a}) + b^2(a)$. Minimális varianciájú torzítatlan becslő (MVU becslő)

$$var(\hat{a}) \geq CRLB(a)$$

$$var(\hat{a}) \geq \left[-E \left(\frac{\partial^2 \ln f(z; a)}{\partial a^2} \right) \right]^{-1},$$

$$\frac{\partial \ln f(z; a)}{\partial a} = I(a)(g(z) - a),$$

$$var(\hat{a}) \geq \frac{\sigma_w^2}{\sum_{n=0}^{N-1} \left[\frac{\partial s_n(a)}{\partial a} \right]^2}$$

$$\hat{a} = g(z) = (U^T U)^{-1} U^T z,$$

$$C_{\hat{a}} = I^{-1}(a) = \sigma^2 (U^T U)^{-1}$$

Lineáris modell + Gauss eloszlású fehér zaj: Legjobb lineáris torzítatlan becslő (BLUE):

$$\hat{a} = (U^T C^{-1} U)^{-1} U^T C^{-1} z,$$

$$C_{\hat{a}} = (U^T C^{-1} U)^{-1}$$

Legkisebb négyzetes hibájú (LS) becslők:


$$J(a) = \sum_{k=0}^{N-1} (z_k - s_k(a))^2.$$

$$\hat{a}_{LS} = [U^T U]^{-1} U^T z$$


$$J(a, \hat{a}_{LS}) = z^T (z - U \hat{a}_{LS})$$

4. Modellillesztés


4.1. Regresszió-számítás:



Inverz modellezés:





Visszavezetés FIR problémára (Equation-Error Formulation):




Méréselmélet 12. előadás, 2022. május 18.

A regressziós séma általánosítása:





$$W^* = R^{-1}P$$


$$\nabla(n) = \frac{\partial J(W(n))}{\partial W(n)} = 2R[W(n) - W^*] = 2RV(n)$$







Megfigyelő séma:



Polinomiális szűrő



5. Szűréselmélet alapjai



$$P(n) = E\{[x(n) - \hat{x}(n)][x(n) - \hat{x}(n)]^T\} = E\{\varepsilon(n)\varepsilon^T(n)\}$$

$$\hat{x}(n) = A\hat{x}(n-1) + K(n)[y(n) - CA\hat{x}(n-1)] = A\hat{x}(n-1) + K(n)e(n)$$

$$P_1(n) = [AP(n-1)A^T + Q(n)]$$

$$K(n) = P_1(n)C^T[CP_1(n)C^T + R(n)]^{-1}$$


$$P(n) = [I - K(n)C]P_1(n)$$

$$P(n+1) = E\{[x(n+1) - \hat{x}(n+1)][x(n+1) - \hat{x}(n+1)]^T\} = E\{\varepsilon(n+1)\varepsilon^T(n+1)\}$$


$$\hat{x}(n+1) = A\hat{x}(n) + G(n)[y(n) - C\hat{x}(n)] = A\hat{x}(n) + G(n)e(n)$$

$$G(n) = AP(n)C^T[CP(n)C^T + R(n)]^{-1}$$

$$P(n+1) = [A - G(n)C]P(n)A^T + Q(n)$$



$$e(n) = y(n) - \hat{y}(n)$$



$$e(n) = y(n) - \hat{y}(n)$$





6. LS becslők rekurzív számítása

$$\hat{a}(n+1) = \hat{a}(n) + G(n)[z(n) - u(n)\hat{a}(n)]$$

$$G(n) = \frac{P(n)u^T(n)}{1 + u(n)P(n)u^T(n)}$$


$$P(n+1) = [I - G(n)u(n)]P(n)$$

7. Modellalapú jelfeldolgozás




$$\begin{aligned} \mathbf{x}(n+1) &= \mathbf{x}(n); \quad y(n) = \mathbf{c}^T(n)\mathbf{x}(n), \\ \hat{\mathbf{x}}(n+1) &= \hat{\mathbf{x}}(n) + \mathbf{g}(n)\mathbf{c}^T(n)[\mathbf{x}(n) - \hat{\mathbf{x}}(n)] \\ \mathbf{x}(n+1) - \hat{\mathbf{x}}(n+1) &= (\mathbf{I} - \mathbf{g}(n)\mathbf{c}^T(n))[\mathbf{x}(n) - \hat{\mathbf{x}}(n)], \\ \mathbf{x}(n+1) - \hat{\mathbf{x}}(n+1) &= \prod_{k=0}^n (\mathbf{I} - \mathbf{g}(k)\mathbf{c}^T(k))[\mathbf{x}(0) - \hat{\mathbf{x}}(0)] \\ \prod_{k=0}^{N-1} (\mathbf{I} - \mathbf{g}(k)\mathbf{c}^T(k)) &= \mathbf{0}. \end{aligned}$$


$$\begin{aligned} \begin{bmatrix} \mathbf{x}^T(n+1) & y(n) \end{bmatrix} \begin{bmatrix} \mathbf{x}(n+1) \\ y(n) \end{bmatrix} &= \begin{bmatrix} \mathbf{x}^T(n) & u(n) \end{bmatrix} \mathbf{T}^T \mathbf{T} \begin{bmatrix} \mathbf{x}(n) \\ u(n) \end{bmatrix}, \\ \sum_{k=0}^{N-1} x_k^2(n+1) + y^2(n) &= \sum_{k=0}^{N-1} x_k^2(n) + u^2(n). \\ \sum_{k=0}^{N-1} x_k^2(n+1) - \sum_{k=0}^{N-1} x_k^2(n) &= -y^2(n), \end{aligned}$$



Direkt struktúra:



Hullámdigitális struktúra:



Köszönöm a figyelmet!