

Méréselmélet

6. fejezet: LS becslők rekurzív számítása

2022. április 6.

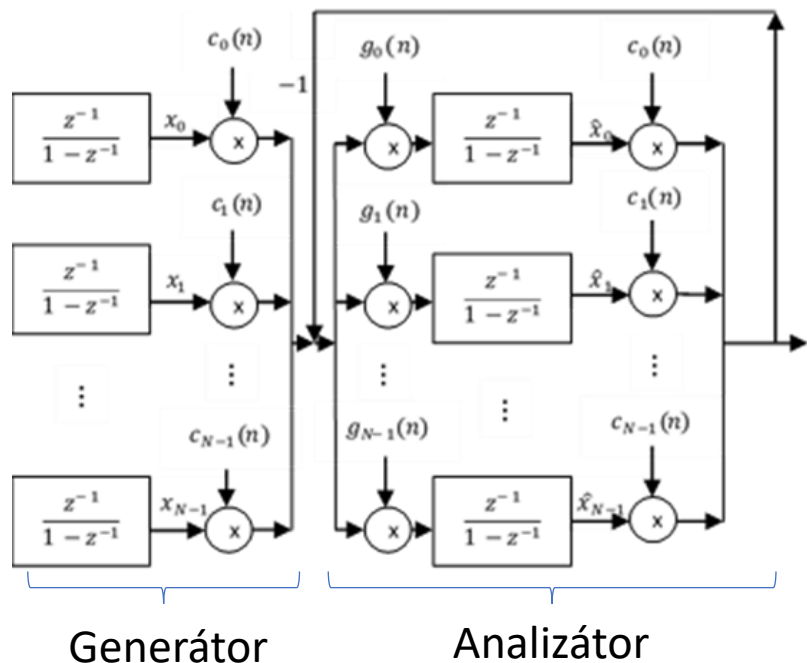
Némi útmutatás a 2. házi feladathoz:

1.1. Állítson elő $u(n), n = 0, 1, \dots$ diszkrét értéksorozatot **multiszinusz generátor** „segítségével”, mégpedig úgy, hogy a diszkrét jel **$M = 100$ harmonikus komponensből álljon**, az egyes harmonikus komponensek amplitúdója egységnyi, kezdőfázisa véletlen, és a sorozat várható értéke pedig 1 legyen!

$$u(n) = 1 + \sum_{m=1}^M \cos\left(\frac{2\pi}{N}mn + \varphi_m\right)$$

$$= 1 + \frac{1}{2} \sum_{m=1}^M \left(e^{j\left(\frac{2\pi}{N}mn + \varphi_m\right)} + e^{-j\left(\frac{2\pi}{N}mn + \varphi_m\right)} \right) \quad \text{ahol } N = 2M + 1$$

A multiszinusz generátort a jegyzet **46. ábrának** megfelelően készítse el! Ügyeljen arra, hogy a generált jel a vizsgált frekvenciatartomány egészében megfelelő gerjesztést adjon (max. 3 pont)! Vizsgálja meg, hogy hogyan alakul a generált jel csúcsértéke, és hasonlítsa össze azzal az esettel, amikor a kezdőfázisok rendre nullák (max. 2 pont)!



$$e^{j\left(\frac{2\pi}{N}mn + \varphi_m\right)} + e^{-j\left(\frac{2\pi}{N}mn + \varphi_m\right)} = e^{j\frac{2\pi}{N}mn} e^{j\varphi_m} + e^{-j\frac{2\pi}{N}mn} e^{-j\varphi_m} =$$

$$= c_m(n)x_m + c_{N-m}(n)x_{N-m}$$

$$x_0 = 1, \quad x_m = x_{N-m}^* = \frac{1}{2} e^{j\varphi_m}, \quad m = 1, \dots, M$$

$$c_0 = 1, \quad c_m(n) = c_{N-m}^*(n) = e^{j\frac{2\pi}{N}mn}, \quad m = 1, \dots, M$$

$$c_m(n) = e^{j\frac{2\pi}{N}mn}, \quad g_m(n) = \frac{1}{N} e^{-j\frac{2\pi}{N}mn}, \quad m = 0, 1, \dots, N-1,$$

1.2. Készítsen az előző pont szerinti generátor jelével gerjesztett rendszerek kimeneti jelének analizálására alkalmas rekurzív multiszinusz analizátort, ugyancsak a 46. ábrán látható elrendezést követve, amely a bemenetére kapcsolt jelből képes kiszámítani az abban levő harmonikus komponensek amplitúdóját és fázisát! Az 1.1. pont szerinti jel és az analizátor által rekonstruált jel különbségét ábrázolva mutassa be, hogy a generátor-analizátor pár megfelelően működik (max. 5 pont)!

5. Szűréselmélet alapjai: **Lényeges üzenetek**


(Jegyzet 55-67. oldalak)

5.1. Optimális nemrekurzív becslő (skalár Wiener Szűrő)

Keressük x legjobb becslőjét

$$\hat{x} = \sum_{k=0}^{N-1} a_k y_k$$

A legjobb becslés geometriai interpretációja (29. ábra):



Legjobbnek azt a becslést tekintjük, amelyik legkisebb hibával jár: ez az x vektor altérre történő merőleges vetítésével áll elő.

$$\frac{\partial E\{e^2\}}{\partial a_j} = 0, E\{ey_j\} = 0, \forall j - re.$$

Ez utóbbit ortogonalitási egyenletnek nevezzük, mert a vektorokkal történő geometriai interpretációban éppen azt fejezi ki, hogy az optimális beállítás esetén az e hibavektor merőleges valamennyi y_j vektorra.


Ez mátrix formában

$$\mathbf{W} = \mathbf{R}_{yy}^{-1} \mathbf{P}_{xy} \quad (\text{ahol } \mathbf{W} = [a_0 \ a_1 \ \dots \ a_{N-1}]^T) \quad E\{e^2\} \Big|_{min} = E\{x^2\} - \mathbf{P}_{xy}^T \mathbf{R}_{yy}^{-1} \mathbf{P}_{xy} = E\{x^2\} - \mathbf{P}_{xy}^T \mathbf{W}$$

Rekurzív becslő az optimális nemrekurzív becslőből

A rekurzív eljárás nagy előnye, hogy nem kell megvárni az összes adatot: folyamatosan számolható az egyre jobb minőségű becslő.

$$\begin{aligned} \hat{x}(n+1) &= a(n+1)\hat{x}(n) + b(n+1)y(n) = \\ &= \hat{x}(n) + \underbrace{b(n+1)(y(n) - \hat{x}(n))}_{\text{korrekciós tag}} \end{aligned}$$



Lineáris átlagoló:
$$\hat{x}(n+1) = \frac{n}{n+1} \hat{x}(n) + \frac{1}{n+1} y(n) = \hat{x}(n) + \frac{1}{n+1} (y(n) - \hat{x}(n))$$




5.2. Optimális rekurzív becslő (skalár Kalman szűrő és prediktor)

A modell, amit alkalmazunk a legegyszerűbb állapotváltozós modell, amit egy Gauss eloszlású fehér-zaj folyamat gerjeszt.

$$x(n) = ax(n-1) + w(n)$$

$$R_{xx}(j) = a^{|j|}R_{xx}(0)$$

$$E\{w(n)\} = 0, E\{w(n)w(j)\} = \begin{cases} 0 & n \neq j \\ \sigma_w^2 & n = j \end{cases}$$



elsőrendű autoregresszív folyamat

$$\hat{x}(n) = a(n)\hat{x}(n-1) + b(n)y(n)$$

Keressük az optimális súlytényezőket: $\frac{\partial E\{e^2(n)\}}{\partial a(n)} = -2E\{e(n)\hat{x}(n-1)\} = 0$, $\frac{\partial E\{e^2(n)\}}{\partial b(n)} - 2E\{e(n)y(n)\} = 0$
Nagyon fontos eredmény: „ortogonalitás”!

$$a(n) = a[(1 - b(n)c)]$$

$$\hat{x}(n) = a\hat{x}(n-1) + b(n)(y(n) - ca\hat{x}(n-1))$$

b(n) meghatározása:

$$E\{e^2(n)\} = E\{[ae(n-1) + w(n) - b(n)(ace(n-1) + cw(n) + n(n))]^2\} = p(n)$$

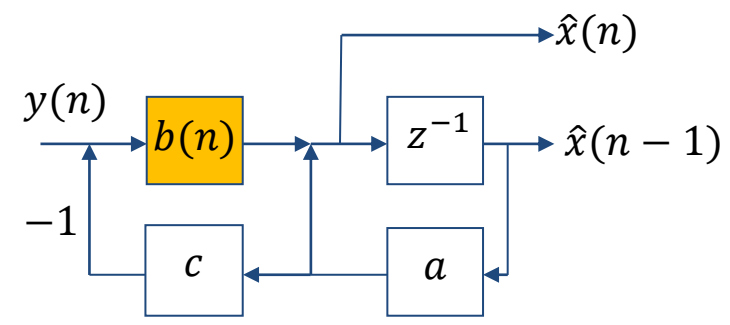
$$E\{e^2(n)\} = E\{[a[1 - b(n)c]e(n-1) + [1 - b(n)c]w(n) - b(n)n(n)]^2\}$$

$$E\{e(n-1)w(n)\} = 0 \quad E\{e(n-1)n(n)\} = 0 \quad E\{w(n)n(n)\} = 0$$

$$b(n) \Big|_{opt} = \frac{a^2cp(n-1) + c\sigma_w^2}{a^2c^2p(n-1) + c^2\sigma_w^2 + \sigma_n^2}$$

$$p(n) = a^2[1 - b(n)c]^2p(n-1) + [1 - b(n)c]^2\sigma_w^2 + b^2(n)\sigma_n^2$$

(1) $p_1(n) = a^2p(n-1) + \sigma_w^2$ (2) $b(n) = cp_1(n)[c^2p_1(n) + \sigma_n^2]^{-1}$
 (3) $p(n) = [1 - b(n)c]p_1(n)$ $p(0)$ kell hozzá!



Optimális rekurzív becslő (skalár Kalman szűrő és prediktor):

$$x(n) = ax(n-1) + w(n)$$

$$y(n) = cx(n) + n(n)$$

helyett

$$\hat{x}(n) = a\hat{x}(n-1) + b(n)(y(n) - ca\hat{x}(n-1))$$

$$(1) p_1(n) = a^2p(n-1) + \sigma_w^2$$

$$(2) b(n) = cp_1(n)[c^2p_1(n) + \sigma_n^2]^{-1} \quad n = 1, 2, \dots$$

$$(3) p(n) = [1 - b(n)c]p_1(n) \quad p(0) \text{ kell hozzá!}$$

$$x(n+1) = ax(n) + w(n)$$

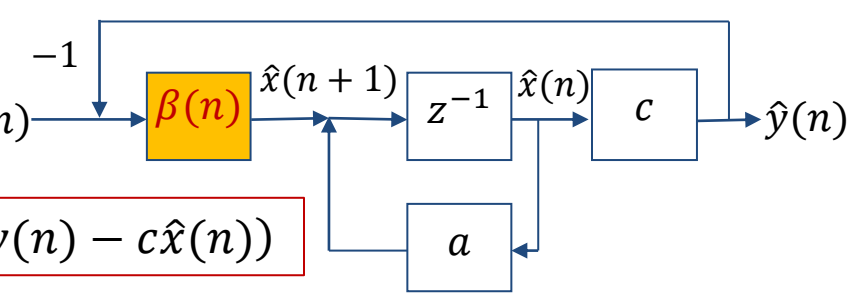
$$y(n) = cx(n) + n(n)$$

$$\hat{x}(n+1) = a\hat{x}(n) + \beta(n)(y(n) - c\hat{x}(n))$$

$$(1) \beta(n) = acp(n)[c^2p(n) + \sigma_n^2]^{-1},$$

$$(2) p(n+1) = a(a - \beta(n)c)p(n) + \sigma_w^2 \quad n = 0, 1, 2, \dots$$

$p(0)$ kell hozzá!



Optimális rekurzív becslő (vektor Kalman szűrő és prediktor):

$$x(n) = Ax(n-1) + w(n)$$

$$y(n) = Cx(n) + n(n)$$

helyett

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

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

$$(2) K(n) = P_1(n)C^T[CP_1(n)C^T + R(n)]^{-1}$$

$$(3) P(n) = [I - K(n)C]P_1(n) \quad n = 1, 2, \dots \quad P(0) \text{ kell hozzá!}$$

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

$$trP(n) \rightarrow \text{minimum!}$$

$$x(n+1) = Ax(n) + w(n),$$

$$y(n) = Cx(n) + n(n)$$

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

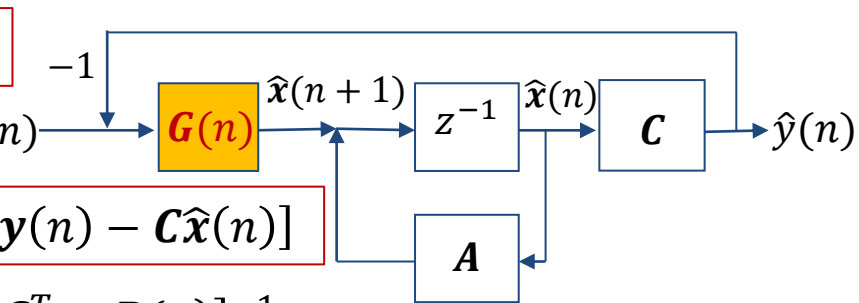
$$(1) G(n) = AP(n)C^T[CP(n)C^T + R(n)]^{-1}$$

$$(2) P(n+1) = [A - G(n)C]P(n)A^T + Q(n) \quad n = 0, 1, 2, \dots$$

$P(0)$ kell hozzá!

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

$$trP(n+1) \rightarrow \text{minimum!}$$



A Kalman prediktor levezetés még egyszer!

$x(n+1) = Ax(n) + w(n)$
 $y(n) = Cx(n) + n(n)$,
 $w(n)$ az ún. rendszer-zaj,
 $n(n)$ az ún. megfigyelési-zaj.

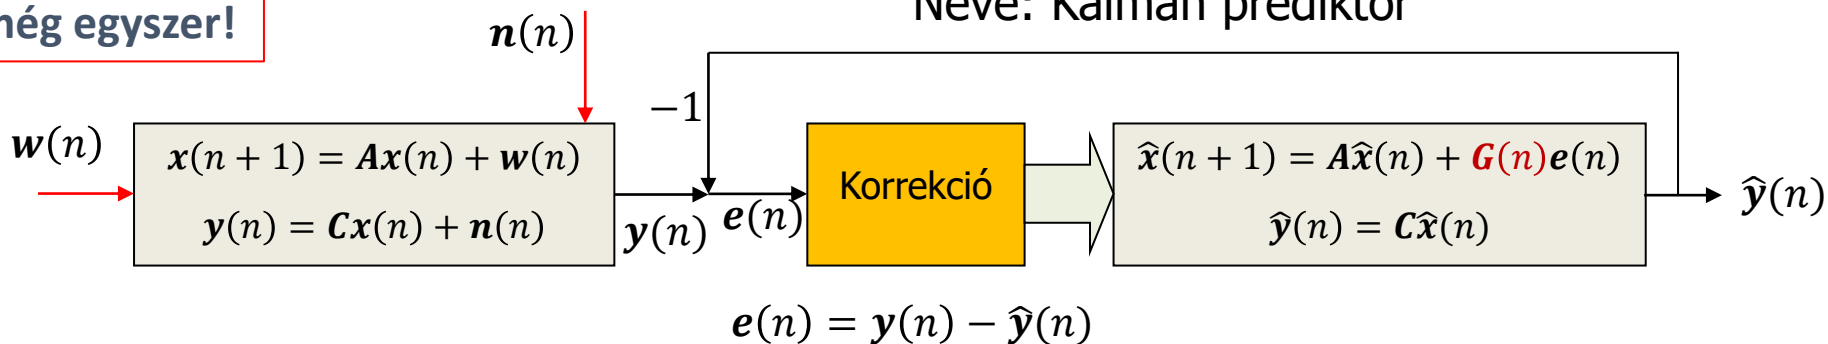
Mind a rendszer-, mind a megfigyelési-zaj vektor egymástól és a rendszer állapotától független nulla várható értékű fehér Gauss folyamat.

$Q(n) = E\{w(n)w^T(n)}$ Keressük azt a $G(n)$ mátrixot (az ún. prediktor erősítést), amely mellett a becslési hiba

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

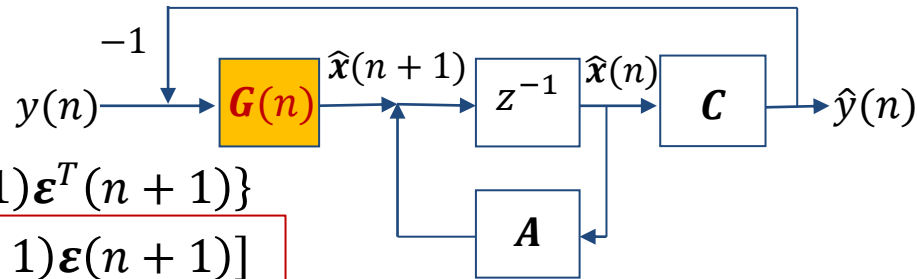
$$trP(n+1) = E[\varepsilon^T(n+1)\varepsilon(n+1)]$$

Neve: Kalman prediktor



A mérési eljárás, amit a kiegészített modellhez rendelünk egy megfigyelő:

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



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

$$\varepsilon(n+1) = [A - G(n)C]\varepsilon(n) + w(n) - G(n)n(n)$$

$$E[\varepsilon(n+1)\varepsilon^T(n+1)] = E\left\{[[A - G(n)C]\varepsilon(n) + w(n) - G(n)n(n)][[A - G(n)C]\varepsilon(n) + w(n) - G(n)n(n)]^T\right\}$$

$$= [A - G(n)C]E[\varepsilon(n)\varepsilon^T(n)][A - G(n)C]^T + E[w(n)w^T(n)] + G(n)E[n(n)n^T(n)]G^T(n)$$

$$+ [A - G(n)C]E[\varepsilon(n)w^T(n)] + [A - G(n)C]E[\varepsilon(n)n^T(n)]G^T(n) + E[w(n)\varepsilon^T(n)][A - G(n)C]^T - E[w(n)n^T(n)]G^T(n) - G(n)E[n(n)\varepsilon^T(n)][A - G(n)C]^T - G(n)E[n(n)w^T(n)]$$

$$E\{\varepsilon(n)w^T(n)\} = 0,$$

$$E\{\varepsilon(n)n^T(n)\} = 0$$

$$E\{w(n)n^T(n)\} = 0$$

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

$$\frac{\partial \text{tr} \mathbf{P}(n+1)}{\partial \mathbf{G}(n)} = \frac{\partial \text{tr}[(\mathbf{A} - \mathbf{G}(n)\mathbf{C})\mathbf{P}(n)(\mathbf{A} - \mathbf{G}(n)\mathbf{C})^T + \mathbf{Q}(n) + \mathbf{G}(n)\mathbf{R}(n)\mathbf{G}^T(n)]}{\partial \mathbf{G}(n)} = \mathbf{0}.$$

A deriválásnál a következő szabályokat alkalmaztuk:

$$\frac{\partial \text{tr} \mathbf{P}(n+1)}{\partial \mathbf{G}(n)} = -2[\mathbf{A} - \mathbf{G}(n)\mathbf{C}]\mathbf{P}(n)\mathbf{C}^T + 2\mathbf{G}(n)\mathbf{R}(n) = \mathbf{0}.$$

$$\frac{\partial \text{tr}[\mathbf{XW}\mathbf{X}^T]}{\partial \mathbf{X}} = \mathbf{XW}^T + \mathbf{XW}; \quad \frac{\partial \text{tr}[\mathbf{XW}]}{\partial \mathbf{X}} = \mathbf{W}^T; \quad \frac{\partial \text{tr}[\mathbf{W}\mathbf{X}^T]}{\partial \mathbf{X}} = \mathbf{W},$$

$$\mathbf{G}(n) = \mathbf{A}\mathbf{P}(n)\mathbf{C}^T[\mathbf{C}\mathbf{P}(n)\mathbf{C}^T + \mathbf{R}(n)]^{-1}$$

ahol a \mathbf{W} mátrix az \mathbf{X} mátrixtól független.

Optimális rekurzív becslő (vektor Kalman szűrő és prediktor) paraméterbecslésre: $\mathbf{A} = \mathbf{I}$ $\mathbf{w}(n)=0$

$$\mathbf{x}(n) = \mathbf{x}(n-1) \quad \mathbf{x} \text{ az ismeretlen paraméter}$$

$$\mathbf{y}(n) = \mathbf{C}\mathbf{x}(n) + \mathbf{n}(n) \quad \mathbf{C} = \mathbf{C}(n) \text{ a regressziós vektor}$$

$$\mathbf{x}(n+1) = \mathbf{x}(n) \quad \mathbf{x} \text{ az ismeretlen paraméter}$$

$$\mathbf{y}(n) = \mathbf{C}\mathbf{x}(n) + \mathbf{n}(n)$$

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

$$(1) \mathbf{G}(n) = \mathbf{P}(n)\mathbf{C}^T[\mathbf{C}\mathbf{P}(n)\mathbf{C}^T + \mathbf{R}(n)]^{-1}$$

$$(2) \mathbf{P}(n+1) = [\mathbf{I} - \mathbf{G}(n)\mathbf{C}]\mathbf{P}(n)$$

$$(1) \mathbf{P}_1(n) = \mathbf{P}(n-1)$$

$$(2) \mathbf{K}(n) = \mathbf{P}_1(n)\mathbf{C}^T[\mathbf{C}\mathbf{P}_1(n)\mathbf{C}^T + \mathbf{R}(n)]^{-1}$$

$$(3) \mathbf{P}(n) = [\mathbf{I} - \mathbf{K}(n)\mathbf{C}]\mathbf{P}_1(n) \quad n = 1, 2, \dots \quad \mathbf{P}(0) \text{ kell hozzá!}$$

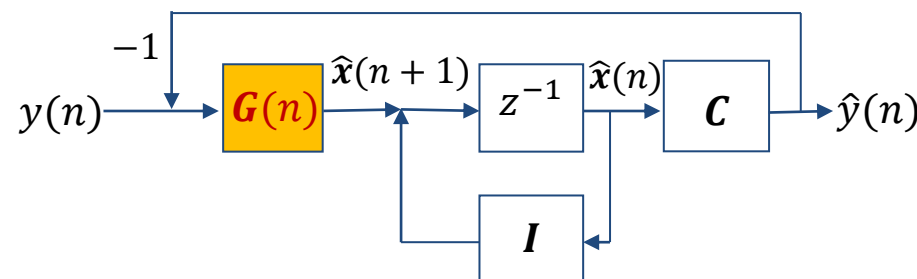
$$n = 0, 1, 2, \dots \quad \mathbf{P}(0) \text{ kell hozzá!}$$

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

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

$$\text{tr} \mathbf{P}(n) \rightarrow \text{minimum!}$$

$$\text{tr} \mathbf{P}(n+1) \rightarrow \text{minimum!}$$



6. LS becslők rekurzív számítása

(Jegyzet 71-75. oldalak)

$$\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{w}$$

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

6.1. A lineáris megfigyelési modellt alkalmazó LS becslők rekurzív számítása

A továbbiakban is n két dolgot jelöl: (1) az eddig figyelembe vett minták számát (az egyes minták indexelhetők például $k = 0, 1, \dots, n - 1$ jelöléssel); (2) Az n -edik „időpillanatban” vett mintát, ami már az $n + 1$ -edik mintavett adat. Ezzel a fenti összefüggés n minta feltételezésével: $\mathbf{z}(n) = \mathbf{U}(n)\mathbf{a}(n) + \mathbf{w}(n)$, amihez tartozóan tudjuk, hogy

$$\hat{\mathbf{a}}(n) = [\mathbf{U}^T(n)\mathbf{U}(n)]^{-1}\mathbf{U}^T(n)\mathbf{z}(n) = \mathbf{P}(n)\mathbf{U}^T(n)\mathbf{z}(n). \quad \mathbf{P}(n) = [\mathbf{U}^T(n)\mathbf{U}(n)]^{-1}$$
 Ha veszünk egy újabb mintát, akkor

$$\mathbf{z}(n + 1) = \mathbf{U}(n + 1)\mathbf{a}(n + 1) + \mathbf{w}(n + 1) = \begin{bmatrix} \mathbf{z}(n) \\ z(n) \end{bmatrix} = \begin{bmatrix} \mathbf{U}(n) \\ \mathbf{u}(n) \end{bmatrix} \mathbf{a}(n + 1) + \begin{bmatrix} \mathbf{w}(n) \\ w(n) \end{bmatrix},$$

ahol $z(n)$ skalár, az $n + 1$ -edik megfigyelési érték, $\mathbf{u}(n)$ sorvektor, a regressziós vektor $n + 1$ -edik sora, és végül $w(n)$ skalár, az $n + 1$ -edik zajkomponens. Ezekkel a jelölésekkel:

$$\hat{\mathbf{a}}(n + 1) = \left[\begin{bmatrix} \mathbf{U}^T(n) & \mathbf{u}^T(n) \end{bmatrix} \begin{bmatrix} \mathbf{U}(n) \\ \mathbf{u}(n) \end{bmatrix} \right]^{-1} \begin{bmatrix} \mathbf{U}^T(n) & \mathbf{u}^T(n) \end{bmatrix} \begin{bmatrix} \mathbf{z}(n) \\ z(n) \end{bmatrix},$$

illetve a műveletek elvégzésével

$$\hat{\mathbf{a}}(n + 1) = \left[[\mathbf{U}^T(n)\mathbf{U}(n) + \mathbf{u}^T(n)\mathbf{u}(n)] \right]^{-1} [\mathbf{U}^T(n)\mathbf{z}(n) + \mathbf{u}^T(n)z(n)] = \mathbf{P}(n + 1)[\mathbf{U}^T(n)\mathbf{z}(n) + \mathbf{u}^T(n)z(n)].$$

Az ebben szereplő mátrix invertálást az ún. mátrix inverziós lemma felhasználásával végezzük:

$$[\mathbf{A} + \mathbf{BCD}]^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{B}[\mathbf{C}^{-1} + \mathbf{DA}^{-1}\mathbf{B}]^{-1}\mathbf{DA}^{-1}$$

$$\boxed{[A + BCD]^{-1} = A^{-1} - A^{-1}B[C^{-1} + DA^{-1}B]^{-1}DA^{-1}} \quad \left[[U^T(n)U(n) + u^T(n)u(n)] \right]^{-1} = P(n+1) \quad \text{ahol most}$$

$$A = P^{-1}(n); B = u^T(n); D = u(n); C = 1, \text{ ezért } P(n+1) = P(n) - P(n)u^T(n)[1 + u(n)P(n)u^T(n)]^{-1}u(n)P(n) =$$

$$= P(n) - \frac{P(n)u^T(n)u(n)P(n)}{1 + u(n)P(n)u^T(n)}, P(0) \text{ ismeretében nincs további mátrix invertálás! Skalár!}$$

Fontos üzenet: Az egy diáddal módosított mátrix inverze mátrix szorzásokkal kiszámítható! Ennek felhasználásával:

$$\hat{a}(n+1) = P(n+1)[U^T(n)z(n) + u^T(n)z(n)] = \hat{a}(n) + P(n)u^T(n)z(n) -$$

$$- \frac{P(n)u^T(n)u(n)}{1 + u(n)P(n)u^T(n)}\hat{a}(n) - \frac{P(n)u^T(n)u(n)P(n)}{1 + u(n)P(n)u^T(n)}u^T(n)z(n). \quad \text{Itt a második és a negyedik tagot közös nevezőre hozva:}$$

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

$$= G(n)z(n) \quad \text{Ezzel: } \boxed{\hat{a}(n+1) = \hat{a}(n) + G(n)[z(n) - u(n)\hat{a}(n)]} \quad \text{Itt } u(n)\hat{a}(n) = \hat{z}(n) \text{ az új mérés becslése!}$$

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

$$\boxed{P(n+1) = [I - G(n)u(n)]P(n)}$$

Az iteráció $n = 0$ -tól indul. $\hat{a}(0)=?$ $P(0)=?$

Ezeket vagy meg tudjuk becsülni, vagy megoldjuk az LS becslést a paraméter vektor dimenziójának megfelelő mérési adat alapján, és annak eredményét használjuk az iteratív megoldás kiindulópontjaként.

$$\boxed{J(a, \hat{a}) = (z - Ua)^T Q(n)(z - Ua)}$$

ahol Q diagonális súlyozó mátrix, tehát $Q(n) = \text{diag}\langle q_0, q_1, \dots, q_{n-1} \rangle$

$$\text{ill. } Q(n+1) = \text{diag}\langle q_0, q_1, \dots, q_{n-1}, q_n \rangle$$

Ehhez a mátrix inverziós lemma \mathbf{C} mátrixát $\mathbf{C} = 1$ helyett $\mathbf{C} = q_n$ skálár értékre kell állítanunk. Ezzel:

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

Ha súlyozó mátrix egy diagonális kovariancia-mátrix inverze, azaz

$$\mathbf{Q}(n) = \text{diag}\langle 1/\sigma_0^2, 1/\sigma_1^2, \dots, 1/\sigma_{n-1}^2 \rangle, \mathbf{Q}(n+1) = \text{diag}\langle 1/\sigma_0^2, 1/\sigma_1^2, \dots, 1/\sigma_{n-1}^2, 1/\sigma_n^2 \rangle,$$

akkor :

$$\mathbf{G}(n) = \frac{\mathbf{P}(n)\mathbf{u}^T(n)}{\sigma_n^2 + \mathbf{u}(n)\mathbf{P}(n)\mathbf{u}^T(n)}$$

A többi változatlan!

Ha a kovariancia mátrix **nem** lenne **diagonális**, akkor a megismert **fehértési eljárás** alkalmazásával, azaz egy transzformáció közbeiktatásával juthatunk el a rekurzív forma alkalmazhatóságához.

Mindezekkel együtt rekurzív megoldást tudunk adni a **Gauss-Markov**, a **BLUE** és a **súlyozott LS** becslések esetére!

Egy további hasznos súlyozási forma lehet a $\mathbf{Q}(n) = \text{diag}\langle \beta^{n-1}, \beta^{n-2}, \dots, 1 \rangle$ $\mathbf{Q}(n+1) = \text{diag}\langle \beta^n, \beta^{n-1}, \beta^{n-2}, \dots, 1 \rangle$

$0 < \beta < 1$. Itt a legutolsó mérési adattal képzett négyzetes hiba 1 súllyal szerepel, míg a korábbiak rendre kisebbel.

$$\mathbf{G}(n) = \frac{\mathbf{P}(n)\mathbf{u}^T(n)}{\beta + \mathbf{u}(n)\mathbf{P}(n)\mathbf{u}^T(n)}, \mathbf{P}(n+1) = \frac{1}{\beta} [\mathbf{I} - \mathbf{G}(n)\mathbf{u}(n)]\mathbf{P}(n)$$

Ezzel egy felejtő hatást érvényesítünk, ami nemstacionárius folyamatok esetén előnyös.

6.2. LS becslők számítása kényszerfeltétel esetén

Tételezzük fel, hogy a becsülendő \mathbf{a} paraméter kielégíti az $\mathbf{A}\mathbf{a} = \mathbf{b}$ kényszerfeltételt!

Ekkor feltételes szélsőértéket keresünk a Lagrange multiplikátoros technika segítségével:

$$J(\mathbf{a}) = (\mathbf{z} - \mathbf{U}\mathbf{a})^T(\mathbf{z} - \mathbf{U}\mathbf{a}) + \boldsymbol{\lambda}^T(\mathbf{A}\mathbf{a} - \mathbf{b}), \frac{\partial J(\mathbf{a})}{\partial \mathbf{a}} = -2\mathbf{U}^T(\mathbf{z} - \mathbf{U}\mathbf{a}) + \mathbf{A}^T\boldsymbol{\lambda} = 0.$$

$$\text{Ebből a kényszerfeltételt kielégítő } \hat{\mathbf{a}}_c \text{ megoldás: } \hat{\mathbf{a}}_c = [\mathbf{U}^T\mathbf{U}]^{-1}\mathbf{U}^T\mathbf{z} - [\mathbf{U}^T\mathbf{U}]^{-1}\mathbf{A}^T\frac{\boldsymbol{\lambda}}{2}.$$

Mivel ez kielégíti a kényszerfeltételt ($\hat{\mathbf{a}}$ a kényszer nélküli becslőt jelöli):

$$\mathbf{A}\hat{\mathbf{a}}_c = \mathbf{A}[\mathbf{U}^T\mathbf{U}]^{-1}\mathbf{U}^T\mathbf{z} - \mathbf{A}[\mathbf{U}^T\mathbf{U}]^{-1}\mathbf{A}^T\frac{\boldsymbol{\lambda}}{2} = \mathbf{A}\hat{\mathbf{a}} - \mathbf{A}[\mathbf{U}^T\mathbf{U}]^{-1}\mathbf{A}^T\frac{\boldsymbol{\lambda}}{2} = \mathbf{b}$$

$$A\hat{\mathbf{a}}_c = A[\mathbf{U}^T \mathbf{U}]^{-1} \mathbf{U}^T \mathbf{z} - A[\mathbf{U}^T \mathbf{U}]^{-1} A^T \frac{\lambda}{2} = A\hat{\mathbf{a}} - A[\mathbf{U}^T \mathbf{U}]^{-1} A^T \frac{\lambda}{2} = \mathbf{b} \quad \text{Ebből: } \frac{\lambda}{2} = [A[\mathbf{U}^T \mathbf{U}]^{-1} A^T]^{-1} (A\hat{\mathbf{a}} - \mathbf{b}),$$

amivel $\hat{\mathbf{a}}_c = \hat{\mathbf{a}} - [\mathbf{U}^T \mathbf{U}]^{-1} A^T [A[\mathbf{U}^T \mathbf{U}]^{-1} A^T]^{-1} (A\hat{\mathbf{a}} - \mathbf{b}).$

6.3. Nemlineáris megfigyelési modellt alkalmazó LS becslők számítása

A megfigyelési modell: $s(\mathbf{a}) \neq \mathbf{U}\mathbf{a}$. A kritériumfüggvény deriváltja:

$$\frac{\partial}{\partial \mathbf{a}} (\mathbf{z} - s(\mathbf{a}))^T (\mathbf{z} - s(\mathbf{a})) = -2 \frac{\partial s^T(\mathbf{a})}{\partial \mathbf{a}} (\mathbf{z} - s(\mathbf{a})) = -2 \mathbf{g}(\mathbf{a}) = 0. \quad \text{A Newton módszer szerint a } \mathbf{g}(\mathbf{a}) = 0 \text{ egyenlet iteratív megoldása:}$$

$$\left. \frac{\partial \mathbf{g}(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} = \frac{\mathbf{g}(\mathbf{a}_0)}{\mathbf{a}_0 - \mathbf{a}_1}, \quad \mathbf{a}_1 = \mathbf{a}_0 - \frac{\mathbf{g}(\mathbf{a}_0)}{\left. \frac{\partial \mathbf{g}(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0}}, \quad \mathbf{a}_2 = \mathbf{a}_1 - \frac{\mathbf{g}(\mathbf{a}_1)}{\left. \frac{\partial \mathbf{g}(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_1}} \dots \quad \text{De kiindulhatunk } s(\mathbf{a}) \text{ Taylor sorából is:}$$

$$\left. \frac{\partial s(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} = \mathbf{U}(\mathbf{a}_0) \text{ jelöléssel, és a második deriváltat tartalmazó tag elhanyagolásával: } s(\mathbf{a}) \cong s(\mathbf{a}_0) + \mathbf{U}(\mathbf{a}_0)(\mathbf{a} - \mathbf{a}_0),$$

$$\left. \frac{\partial s^T(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} (\mathbf{z} - s(\mathbf{a})) = \mathbf{U}^T(\mathbf{a}_0) [\mathbf{z} - [s(\mathbf{a}_0) + \mathbf{U}(\mathbf{a}_0)(\mathbf{a} - \mathbf{a}_0)]] = 0, \quad \hat{\mathbf{a}} \cong \mathbf{a}_0 + [\mathbf{U}^T(\mathbf{a}_0) \mathbf{U}(\mathbf{a}_0)]^{-1} \mathbf{U}^T(\mathbf{a}_0) [\mathbf{z} - s(\mathbf{a}_0)].$$

$$\text{De kiindulhatunk } J(\mathbf{a}) \text{ Taylor sorából is: } J(\mathbf{a}) = J(\mathbf{a}_0) + \left. \frac{\partial J(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} (\mathbf{a} - \mathbf{a}_0) + \frac{1}{2} (\mathbf{a} - \mathbf{a}_0)^T \left. \frac{\partial^2 J(\mathbf{a})}{\partial^2 \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} (\mathbf{a} - \mathbf{a}_0) + \dots$$

Ha $J(\mathbf{a})|_{min} = 0$, akkor kiindulhatunk az első két tagból, és a többit elhanyagoljuk. $\left. \frac{\partial J(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} = \nabla J(\mathbf{a}_0)$ jelöléssel:

$$\nabla J^T(\mathbf{a}_0) \nabla J(\mathbf{a}_0) \hat{\mathbf{a}} = \nabla J^T(\mathbf{a}_0) \nabla J(\mathbf{a}_0) \mathbf{a}_0 - \nabla J^T(\mathbf{a}_0) J(\mathbf{a}_0), \quad \hat{\mathbf{a}} \cong \mathbf{a}_0 - [\nabla J^T(\mathbf{a}_0) \nabla J(\mathbf{a}_0)]^{-1} \nabla J^T(\mathbf{a}_0) J(\mathbf{a}_0)$$

Ha $J(\mathbf{a})|_{min} \neq 0$, akkor a $\nabla J(\mathbf{a}) = \mathbf{0}$ feltétel teljesülését keressük az első és a másodrendű tag figyelembevételével, a többi elhanyagolásával:

$$\nabla J(\mathbf{a}) = 0 = \left. \frac{\partial J(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} + \left. \frac{\partial^2 J(\mathbf{a})}{\partial^2 \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} (\mathbf{a} - \mathbf{a}_0),$$

$$\hat{\mathbf{a}} = \mathbf{a}_0 - \left[\left. \frac{\partial^2 J(\mathbf{a})}{\partial^2 \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} \right]^{-1} \left. \frac{\partial J(\mathbf{a})}{\partial \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} = \mathbf{a}_0 - \left[\left. \frac{\partial^2 J(\mathbf{a})}{\partial^2 \mathbf{a}} \right|_{\mathbf{a}=\mathbf{a}_0} \right]^{-1} \nabla J(\mathbf{a}_0)$$

amit Gauss-Newton módszernek is nevezünk.

Megjegyzés: Egyes feladatok alkalmas transzformációval visszavezethetők lineáris paraméter-függésre. Például a következő hullámforma

$$s(n) = A \cos(2\pi f_0 n + \varphi), \quad n = 0, 1, \dots, N - 1$$

ismeretlen A és φ paramétereinek együttes meghatározása nemlineáris LS probléma.

Ha azonban az ezzel ekvivalens felírás

$$s(n) = A \cos(2\pi f_0 n + \varphi) = B \cos(2\pi f_0 n) + C \sin(2\pi f_0 n)$$

B és C paramétereit becsüljük, akkor a sokkal egyszerűbb lineáris LS problémát kell megoldanunk, és a keresett jellemzőket pedig transzformációval kapjuk:

$$A = \sqrt{B^2 + C^2}, \quad \varphi = \arctan\left(\frac{-C}{B}\right)$$