



Méréselmélet

6. fejezet: LS becslők rekurzív számítása

2021. március 31.

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 **$M = 100$ páratlan harmonikus komponensből álljon**, az egyes harmonikus komponensek amplitúdója egységnyi, kezdőfázisa véletlen, és a sorozat várható értéke pedig 1 legyen!

$$u(n) = 1 + \sum_{i=0}^{M-1} \cos\left(\frac{2\pi}{N}(2i+1)n + \varphi_{2i+1}\right) = 1 + \frac{1}{2} \sum_{i=0}^{M-1} \left(e^{j\left(\frac{2\pi}{N}(2i+1)n + \varphi_{2i+1}\right)} + e^{-j\left(\frac{2\pi}{N}(2i+1)n + \varphi_{2i+1}\right)} \right) \text{ ahol } N = 4M + 1$$

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

$$e^{j\left(\frac{2\pi}{N}(2i+1)n + \varphi_{2i+1}\right)} + e^{-j\left(\frac{2\pi}{N}(2i+1)n + \varphi_{2i+1}\right)} = e^{j\frac{2\pi}{N}(2i+1)n} e^{j\varphi_{2i+1}} + e^{-j\frac{2\pi}{N}(2i+1)n} e^{-j\varphi_{2i+1}} =$$

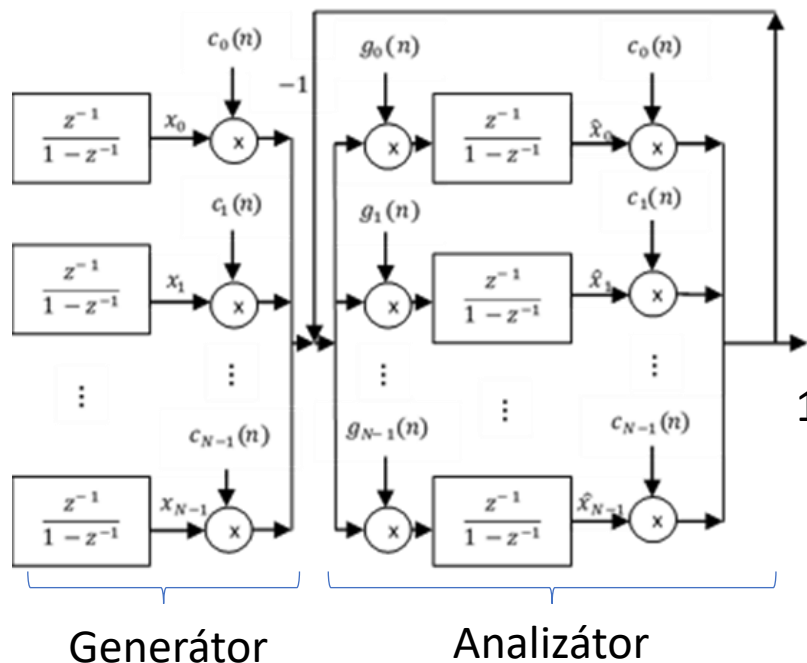
$$= c_{2i+1}(n)x_{2i+1} + c_{N-2i-1}(n)x_{N-2i-1}$$

$$x_0 = 1, \quad x_{2i+1} = x_{N-2i-1}^* = \frac{1}{2} e^{j\varphi_{2i+1}}, \quad i = 0, 1, \dots, M-1, \quad x_{2i} = x_{N-2i}^* = 0, \quad i = 1, \dots, M$$

$$c_0 = 1, \quad c_{2i+1}(n) = c_{N-2i-1}^*(n) = e^{j\frac{2\pi}{N}(2i+1)n}, \quad i = 0, 1, \dots, M-1$$

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

1.2. Készítsen az előző pont szerinti generátor jellel 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.


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

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

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



A megfigyelés lineáris modellje



A rekurzív becslő

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!

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

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



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

$$x(n) = x(n-1)$$

x az ismeretlen paraméter

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

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

$$(1) P_1(n) = P(n-1)$$

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

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

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

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

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

x az ismeretlen paraméter

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

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

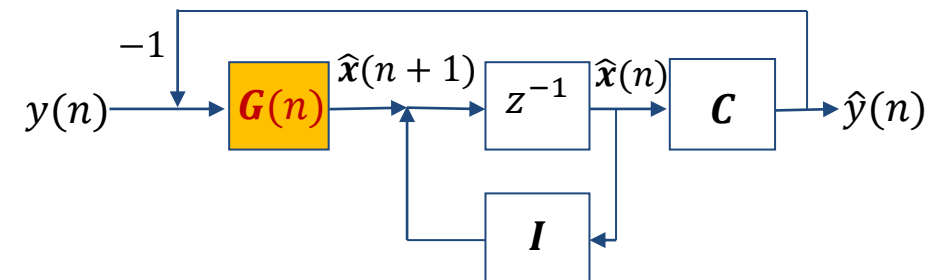
$$(1) G(n) = P(n)C^T [CP(n)C^T + R(n)]^{-1}$$

$$(2) P(n+1) = [I - G(n)C]P(n)$$

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

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

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



6. LS becslők rekurzív számítása

(Jegyzet 68-72. 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 $Q(n) = \text{diag}\langle q_0, q_1, \dots, q_{n-1} \rangle$

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



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

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

Ha súlyozó mátrix egy diagonális kovariancia-mátrix inverze, azaz

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

akkor :

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

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 $Q(n) = \text{diag}\langle \beta^{n-1}, \beta^{n-2}, \dots, 1 \rangle$ $Q(n+1) = \text{diag}\langle \beta^n, \beta^{n-1}, \beta^{n-2}, \dots, 1 \rangle$

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

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

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

6.2. LS becslők számítása kényszerfeltétel esetén

Tételezzük fel, hogy a becsülendő a paraméter kielégíti az $Aa = b$ kényszerfeltételt!

Ekkor feltételes szélsőértéket keresünk a Lagrange multiplikátoros technika segítségével:

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

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

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

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



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

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:

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

Köszönöm a figyelmet!



Dabóczi Tamás, Dobrowiecki Tadeusz, Pálfi Vilmos,
Péceli Gábor, Renczes Balázs, Sujbert László, Virosztek Tamás

Mérés- és adattudomány

Válogatott fejezetek

Szerkesztette
Péceli Gábor



Dabóczi Tamás, Dobrowiecki Tadeusz, Pálfi Vilmos, Péceli Gábor, Renczes Balázs, Sujbert László, Virosztek Tamás

Mérés- és adattudomány
Válogatott fejezetek

Akadémiai Kiadó

ISBN: 978 963 454 379 4

DOI: [10.1556/9789634543794](https://doi.org/10.1556/9789634543794)

Online megjelenés éve: 2020

Hivatkozás:

<https://mersz.hu/meres-es-adattudomany>

[BibTeX](#) [EndNote](#) [Mendeley](#) [Zotero](#)

[Műszaki tudományok](#)