
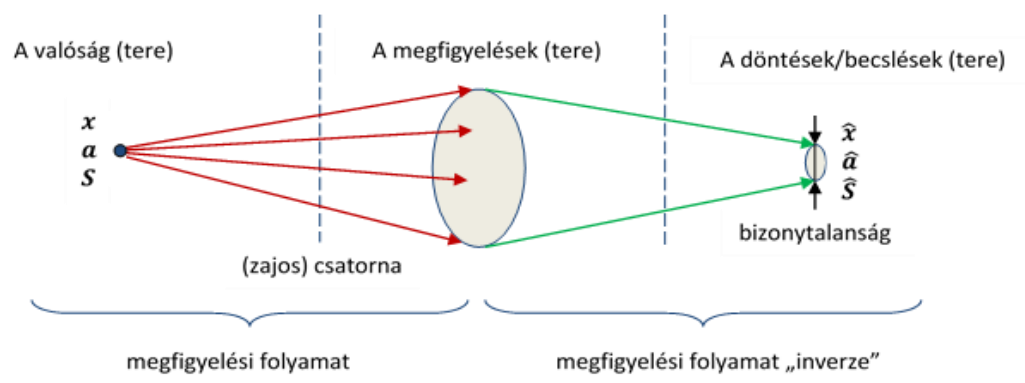


Méréselmélet




3. fejezet: A becsléselmélet alapjai

2022. március 9.




$$P_0(C_{10} - C_{00})f(z|H_0) = P_1(C_{01} - C_{11})f(z|H_1).$$

2. A döntésemélet alapjai




$$\Lambda(z) \begin{cases} > \eta \\ < \eta \end{cases} \begin{matrix} H_1 \\ H_0 \end{matrix}$$


1. Példa:





2. Példa:



3. példa:




3. A becslésemélet alapjai



$$R(\hat{a}, a) = E\{C(\hat{a}, a)\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} C(\hat{a}, a) f(a, z) da dz$$

3.1. Bayes becslők

$$f(a|z) = \frac{f(z|a)f(a)}{f(z)}$$



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

$$\hat{a}_{ABS} = f(a|z) \text{ mediánja.}$$

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

Bayes becslő Gauss eloszlások esetén A megfigyelés modellje legyen lineáris! $z = Ua + n$

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

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


1. Példa:
DC szint zajban:

$$\hat{a}_{MS} = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} z_k}{1 + N \frac{\sigma_a^2}{\sigma_n^2}}, \quad \text{var}\{\tilde{a}\} = \frac{\sigma_a^2}{1 + N \frac{\sigma_a^2}{\sigma_n^2}}, \quad b(a) = \frac{\mu_a - a}{1 + N \frac{\sigma_a^2}{\sigma_n^2}}, \quad \hat{a}_{MAP} = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k z_k}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2}, \quad \text{var}\{\tilde{a}\} = \frac{\sigma_a^2}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2}$$

2. Példa: ismert jel ismeretlen amplitúdója:

3.2. Maximum Likelihood (ML) becslő

3.2.1. Gauss-Markov (GM) becslő:



$$\left. \frac{\partial f(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = 0,$$

$$\left. \frac{\partial \ln f(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = 0$$

Speciális ML becslő: a megfigyelési zaj **Gauss** eloszlású, a megfigyelési egyenlet **lineáris**.

Példa: DC szint zajban:

$$f(z|a) = \frac{1}{(2\pi)^{\frac{N}{2}} |\Sigma_{nn}|^{\frac{1}{2}}} e^{-\frac{1}{2}(z-Ua)^T \Sigma_{nn}^{-1} (z-Ua)}$$

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

$$\text{cov}(\hat{a}_{GM}, \hat{a}_{GM}) = [U^T \Sigma_{nn}^{-1} U]^{-1}$$

$$f(z|a) = \frac{1}{(2\pi\sigma_n^2)^{\frac{N}{2}}} e^{-\frac{1}{2\sigma_n^2} \sum_{k=0}^{N-1} (z_k - a)^2},$$

$$\hat{a}_{ML} = \hat{a}_{GM} = \frac{1}{N} \sum_{k=0}^{N-1} z_k,$$

Lineáris megfigyelési egyenlet és Gauss eloszlású csatorna zaj esetén a legjobb (Gauss-Markov) becslő **az egyszerű átlagolás!**

3.3. Becslők determinisztikus modellel jellemzett paraméterek esetén

3.3.1. Becslések minősítése Torzítatlan becslő: Az a becslő, amelyik várható értékben a helyes értéket adja: $E(a - \hat{a}) = 0$

$$\text{var}(\hat{A}_1) = \text{var}\left[\frac{1}{N} \sum_{k=0}^{N-1} z_k\right] = E\left\{\left(\left(\frac{1}{N} \sum_{k=0}^{N-1} z_k\right) - E\left\{\frac{1}{N} \sum_{k=0}^{N-1} z_k\right\}\right)^2\right\} = E\left\{\left(\frac{1}{N} \sum_{k=0}^{N-1} (z_k - A)\right)^2\right\} = \frac{1}{N^2} \sum_{k=0}^{N-1} \text{var}(z_k) = \frac{1}{N^2} N\sigma^2 = \frac{\sigma^2}{N},$$

$$\text{var}(\hat{A}_2) = \text{var}(z_0) = \sigma^2 > \text{var}(\hat{A}_1)$$

3.3.2. A minimális variancia kritériuma $mse(\hat{a}) = E[(\hat{a} - a)^2]$

Torzítás
Zavarás

$$mse(\hat{a}) = E\{[\hat{a} - E[\hat{a}] + E[\hat{a}] - a]^2\} = E\{[\hat{a} - E[\hat{a}] + b(a)]^2\} = \text{var}(\hat{a}) + b^2(a).$$

3.3.3. Minimális varianciájú, torzítatlan becslők (Minimum Variance Unbiased Estimator, MVU Estimator)

Nem biztos, hogy MVU becslő létezik! Lehet, hogy **nincsen** torzítatlan becslő. Lehet, hogy **egyik** becslő **se** minimális varianciájú.

Érdekes módon van módszer arra, hogy meghatározzuk, hogy mekkora az elvileg elérhető legkisebb variancia!

Cramer-Rao alsó korlát (Cramer-Rao Lower Bound: CRLB, skalár paraméter esete) $var(\hat{a}) \geq CRLB(a)$

Ha $E \left[\frac{\partial \ln f(z; a)}{\partial a} \right] = 0$ akkor $var(\hat{a}) \geq \left[-E \left(\frac{\partial^2 \ln f(z; a)}{\partial a^2} \right) \right]^{-1}$ $\frac{\partial \ln f(z; a)}{\partial a} = I(a)(g(z) - a)$ $\hat{a} = g(z)$ a variancia minimum: $= \frac{1}{I(a)}$.

1. Példa: $z_0 = A + w_0$, $\frac{\partial \ln f(z_0; A)}{\partial A} = \frac{1}{\sigma^2} [z_0 - A]$, $-\frac{\partial^2 \ln f(z_0; A)}{\partial A^2} = \frac{1}{\sigma^2}$, $\hat{A} = g(z_0) = z_0$, $var(\hat{A}) \geq \sigma^2$

2. Példa: $z_k = A + w_k$, $\frac{\partial \ln f(z; A)}{\partial A} = \frac{1}{\sigma^2} \sum_{k=0}^{N-1} (z_k - A)$, $-\frac{\partial^2 \ln f(z; A)}{\partial A^2} = \frac{N}{\sigma^2}$, $\hat{A} = \frac{1}{N} \sum_{k=0}^{N-1} z_k$, $var(\hat{A}) \geq \frac{\sigma^2}{N}$.

3. Példa: $z_k = A + w_k$, $\frac{\partial \ln f(z; \sigma^2)}{\partial \sigma^2} = -\frac{N}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=0}^{N-1} (z_k - A)^2 = \frac{N}{2\sigma^4} \left[\frac{1}{N} \sum_{k=0}^{N-1} (z_k - A)^2 - \sigma^2 \right]$, $\hat{\sigma}^2 = \frac{1}{N} \sum_{k=0}^{N-1} (z_k - A)^2$

Zaj variancia varianciája: $var(\hat{\sigma}^2) \geq \frac{2\sigma^4}{N}$.
4. Példa: $x_k = s_k(a) + w_k$, $-E \left[\frac{\partial^2 \ln f(z; \sigma^2)}{\partial (\sigma^2)^2} \right] = -\frac{N}{2\sigma^4} + \frac{N\sigma^2}{\sigma^6} = \frac{N}{2\sigma^4}$

$var(\hat{a}) \geq \frac{\sigma_w^2}{\sum_{k=0}^{N-1} \left[\frac{\partial s_k(a)}{\partial a} \right]^2}$.
5. Példa: $\alpha = g(a)$ paraméter varianciájának alsó korlátja: $var(\hat{\alpha}) \geq \frac{\left[\frac{\partial g(a)}{\partial a} \right]^2}{E \left\{ \left[\frac{\partial \ln f(z; a)}{\partial a} \right]^2 \right\}} = -\frac{\left[\frac{\partial g(a)}{\partial a} \right]^2}{E \left[\frac{\partial^2 \ln f(z; a)}{\partial a^2} \right]}$.

6. Példa: DC szint (A) teljesítményének (A²) „mérése” a DC szint mérésére alapozva.

$var(\hat{\alpha}) = var(\hat{A}^2) \geq \frac{\left[\frac{\partial g(a)}{\partial a} \right]^2}{E \left\{ \left[\frac{\partial \ln f(z; a)}{\partial a} \right]^2 \right\}} = -\frac{\left[\frac{\partial g(a)}{\partial a} \right]^2}{E \left[\frac{\partial^2 \ln f(z; a)}{\partial a^2} \right]} = \frac{(2A)^2}{\frac{N}{\sigma^2}} = \frac{4A^2 \sigma^2}{N}$

Mivel $E\{\hat{A}^2\} = E^2(\hat{A}) + var(\hat{A}) = A^2 + \frac{\sigma^2}{N} \neq A^2$ A becslés nem torzítatlan.

Mivel $var(\hat{A}^2) = \frac{4A^2 \sigma^2}{N} + \frac{2\sigma^4}{N^2} > CRLB$ a javasolt becslő nem lesz hatásos.

Cramer-Rao alsó korlát (Cramer-Rao Lower Bound: CRLB, vektor-paraméter esete)

Tegyük fel, hogy a mérési (vektor)adatok valószínűség sűrűségfüggvényére teljesül a regularitási feltétel minden \mathbf{a} esetében:

$$E \left[\frac{\partial \ln f(z; \mathbf{a})}{\partial \mathbf{a}} \right] = \mathbf{0}.$$

Ekkor bármely torzítatlan becslőre igaz, hogy a becslő kovariancia mátrixának és

az ún. **Fisher információs mátrix** inverzének a különbsége pozitív szemidefinit: $\mathbf{C}_{\hat{\mathbf{a}}} - \mathbf{I}^{-1}(\mathbf{a}) \geq \mathbf{0}$

A Fisher információs mátrix elemei:

$$I_{ij}(\mathbf{a}) = -E \left(\frac{\partial^2 \ln f(z; \mathbf{a})}{\partial a_i \partial a_j} \right)$$

Egy olyan torzítatlan becslő, amelyik eléri a Cramer-Rao alsó korlátot akkor és csak akkor található, ha:

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

7. Példa: Additív, Gauss eloszlású fehér zajjal terhelt **DC szint és szórásának** mérése mérési sorozatra alapozva:

Ilyenkor a becslő $\hat{\mathbf{a}} = \mathbf{g}(z)$, és a kovariancia minimum $\mathbf{I}^{-1}(\mathbf{a})$.

$z_k = A + w_k$, $k = 0, 1, \dots, N - 1$, ahol a w_k korrelálatlan minden mintával, és valószínűségi sűrűség függvénye: $\mathcal{N}(0, \sigma^2)$.

Most $\mathbf{a} = [A \ \sigma^2]^T$. A sűrűség függvény logaritmus: $\ln f(z; \mathbf{a}) = -\frac{N}{2} \ln 2\pi - \frac{N}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{k=0}^{N-1} (z_k - A)^2$.

$$\mathbf{I}(\mathbf{a}) = -E \begin{bmatrix} \frac{\partial^2 \ln f(z; \mathbf{a})}{\partial A^2} & \frac{\partial^2 \ln f(z; \mathbf{a})}{\partial A \partial \sigma^2} \\ \frac{\partial^2 \ln f(z; \mathbf{a})}{\partial A \partial \sigma^2} & \frac{\partial^2 \ln f(z; \mathbf{a})}{\partial (\sigma^2)^2} \end{bmatrix} = \begin{bmatrix} \frac{N}{\sigma^2} & 0 \\ 0 & \frac{N}{2\sigma^4} \end{bmatrix}.$$

Ez a mátrix diagonális, így könnyen invertálható, amiből:

$$\mathbf{C}_{\hat{\mathbf{a}}} = \begin{bmatrix} \text{var}(\hat{A}) & 0 \\ 0 & \text{var}(\hat{\sigma}^2) \end{bmatrix} \geq \begin{bmatrix} \frac{\sigma^2}{N} & 0 \\ 0 & \frac{2\sigma^4}{N} \end{bmatrix}$$

8. Példa: Ha $\alpha = g(\mathbf{a})$ a becsülendő mennyiség, és az $\hat{\alpha}$ kovarianciája $\mathbf{I}^{-1}(\mathbf{a})$, akkor

$$\mathbf{C}_{\hat{\alpha}} \geq \left(\frac{\partial g(\mathbf{a})}{\partial \mathbf{a}} \right) \left[-E \left[\frac{\partial^2 \ln f(z; \mathbf{a})}{\partial \mathbf{a}^2} \right] \right]^{-1} \left(\frac{\partial g(\mathbf{a})}{\partial \mathbf{a}} \right)^T,$$

ahol a függvénykapcsolat paraméter szerinti deriváltját sorvektorként értelmezzük.

Ha az előző példához kapcsolódóan az $\alpha = g(\mathbf{a}) = A^2/\sigma^2$ jel/zaj viszony becslése varianciájának alsó határát keressük, akkor

$$\frac{\partial g(\mathbf{a})}{\partial \mathbf{a}} = \begin{bmatrix} \frac{\partial g(\mathbf{a})}{\partial A} & \frac{\partial g(\mathbf{a})}{\partial \sigma^2} \end{bmatrix} = \begin{bmatrix} \frac{2A}{\sigma^2} & -\frac{A^2}{\sigma^4} \end{bmatrix}, \quad \text{var}(\hat{\alpha}) \geq \begin{bmatrix} \frac{2A}{\sigma^2} & -\frac{A^2}{\sigma^4} \\ 0 & \frac{2\sigma^4}{N} \end{bmatrix} \begin{bmatrix} \frac{2A}{\sigma^2} \\ -\frac{A^2}{\sigma^4} \end{bmatrix} = \frac{4A^2}{N\sigma^2} + \frac{2A^4}{N\sigma^4} = \frac{4\alpha + 2\alpha^2}{N}$$

Ezt felhasználva a keresett alsó határ:

Megjegyzés: Az előzőekben bemutatott példák közös jellemzője, hogy **determinisztikus paraméter**, és **ismert** valószínűségi sűrűség függvényű **csatorna-karakterisztika** feltételezésével a becslés varianciájának **elvi minimumát** kapjuk meg.

Az, hogy ezt **milyen mérési eljárás** alkalmazása esetén érjük el, ill. **létezik-e, ismert-e** ilyen eljárás, sok esetben **nyitott kérdés**.

A továbbiakban korlátozzuk magunkat arra az esetre, amikor a **megfigyelési modell lineáris**.

Látni fogjuk, hogy ilyenkor hatásos becslőkhöz jutunk, azaz minden esetben elérjük a becslés varianciájára meghatározható alsó korlátot (CRLB).

Additív, Gauss eloszlású fehér zajjal terhelt lineáris modellek esete: $\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{w}$

\mathbf{z}	$N \times 1$	dimenziós megfigyelési vektor
\mathbf{U}	$N \times M$	dimenziós, ismert megfigyelési mátrix
\mathbf{a}	$M \times 1$	dimenziós, becsülendő paramétervektor
\mathbf{w}	$N \times 1$	dimenziós zaj vektor, amelynek valószínűség sűrűségfüggvénye $N(0, \sigma^2 \mathbf{I})$.

a megfigyelési vektor minden eleme az ismeretlen paraméterek lineáris kombinációjaként áll elő, amit additív zaj terhel.

Ahhoz, hogy M paramétert becsülni tudjunk legalább ugyanennyi megfigyelést/mérést kell elvégeznünk, azaz $N \geq M$, ráadásul a zaj hatásának csökkentése érdekében tipikusan $N > M$ vagy $N \gg M$.

Ebben az esetben a CRLB és az ezt elérő MVU becslő kiszámítható:

1. lépés: $\ln f(\mathbf{z}; \mathbf{a})$ számítása;

2. lépés: Az $\mathbf{I}(\mathbf{a}) = -E \left[\frac{\partial^2 \ln f(\mathbf{z}; \mathbf{a})}{\partial \mathbf{a}^2} \right]$ Fisher információs mátrix és abból az $\hat{\mathbf{a}}$ kovariancia mátrixának kiszámítása: $\mathbf{C}_{\hat{\mathbf{a}}} = \mathbf{I}^{-1}(\mathbf{a})$.

3. lépés: A $g(\mathbf{z})$ MVU becslő meghatározása a következő szorzat alakból: $\frac{\partial \ln f(\mathbf{z}; \mathbf{a})}{\partial \mathbf{a}} = \mathbf{I}(\mathbf{a}) [g(\mathbf{z}) - \mathbf{a}]$.

1. lépés: $\ln f(\mathbf{z}; \mathbf{a}) = -\ln(\sqrt{2\pi\sigma^2})^N - \frac{1}{2\sigma^2} (\mathbf{z} - \mathbf{U}\mathbf{a})^T (\mathbf{z} - \mathbf{U}\mathbf{a})$

2. lépés: $\frac{\partial \ln f(\mathbf{z}; \mathbf{a})}{\partial \mathbf{a}} = -\frac{1}{2\sigma^2} \frac{\partial}{\partial \mathbf{a}} [\mathbf{z}^T \mathbf{z} - 2\mathbf{z}^T \mathbf{U}\mathbf{a} + \mathbf{a}^T \mathbf{U}^T \mathbf{U}\mathbf{a}] = \frac{1}{\sigma^2} [\mathbf{U}^T \mathbf{z} - \mathbf{U}^T \mathbf{U}\mathbf{a}]$,

$$\mathbf{I}(\mathbf{a}) = -E \left[\frac{\partial^2 \ln f(\mathbf{z}; \mathbf{a})}{\partial \mathbf{a}^2} \right] = \frac{1}{\sigma^2} \mathbf{U}^T \mathbf{U},$$

$$\mathbf{C}_{\hat{\mathbf{a}}} = \mathbf{I}^{-1}(\mathbf{a}) = \sigma^2 [\mathbf{U}^T \mathbf{U}]^{-1}$$

3. lépés: $\frac{\partial \ln f(\mathbf{z}; \mathbf{a})}{\partial \mathbf{a}} = \mathbf{I}(\mathbf{a}) [g(\mathbf{z}) - \mathbf{a}] = \frac{\mathbf{U}^T \mathbf{U}}{\sigma^2} [(\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T \mathbf{z} - \mathbf{a}]$.

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

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

Vagyis **additív, Gauss** eloszlású **fehér** zajjal terhelt **lineáris** modellek esetében:

- Az MVU becslő: $\hat{\mathbf{a}} = (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T \mathbf{z}$. A becslő **hatásos** és **eléri a CLRB korlátot**;

- A becslő **torzítatlan**, mert: $E(\hat{\mathbf{a}}) = (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T E(\mathbf{U}\mathbf{a} + \mathbf{w}) = \mathbf{a}$;

- A becslő statisztikai viselkedése **teljes mértékben specifikált**, mert $\hat{\mathbf{a}}$ a Gauss eloszlású \mathbf{z} vektornak **lineáris transzformáltja**:

$$\hat{\mathbf{a}} \sim \mathcal{N}(\mathbf{a}, \sigma^2 (\mathbf{U}^T \mathbf{U})^{-1}).$$

Példák ennek a modellcsaládnak az alkalmazására, ahol: $\hat{\mathbf{a}} = g(\mathbf{z}) = (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T \mathbf{z}$,

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

1. Példa: az illesztendő modell a diszkrét n időindex polinomja: $x_n = a_0 + a_1 n + a_2 n^2 + \dots + a_{M-1} n^{M-1} + w_n$

$$\mathbf{z} = \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_{N-1} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 1 & 1 & 1 & \dots & 1 \\ 1 & 2 & 4 & \dots & 2^{M-1} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & N-1 & (N-1)^2 & \dots & (N-1)^{M-1} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_{M-1} \end{bmatrix} + \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{N-1} \end{bmatrix} = \mathbf{U}\mathbf{a} + \mathbf{w},$$

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

$$\hat{\mathbf{a}} \sim \mathcal{N}(\mathbf{a}, \sigma^2 (\mathbf{U}^T \mathbf{U})^{-1})$$

2. Példa: Az illesztendő modell az időben diszkrét Fourier sorfejtés: $x_n = \sum_{k=1}^M a_k \cos \frac{2\pi kn}{N} + \sum_{k=1}^M b_k \sin \frac{2\pi kn}{N} + w_n$
Most DC komponenst nem illesztünk.

$$\mathbf{z} = \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_{N-1} \end{bmatrix} = \begin{bmatrix} \dots & 1 & \dots & \dots & 0 & \dots \\ \dots & \cos \frac{2\pi k}{N} & \dots & \dots & \sin \frac{2\pi k}{N} & \dots \\ \dots & \cos \frac{4\pi k}{N} & \dots & \dots & \sin \frac{4\pi k}{N} & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \dots & \cos \frac{2\pi}{N} (N-1) & \dots & \dots & \sin \frac{2\pi}{N} (N-1) & \dots \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_M \\ b_1 \\ b_2 \\ \vdots \\ b_M \end{bmatrix} + \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{N-1} \end{bmatrix} = \mathbf{U}\mathbf{a} + \mathbf{w}$$

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

$$\hat{\mathbf{a}} \sim \mathcal{N}(\mathbf{a}, \sigma^2 (\mathbf{U}^T \mathbf{U})^{-1})$$

$$(\mathbf{U}^T \mathbf{U})^{-1} = \frac{2}{N} \mathbf{I},$$

$$\hat{a}_k = \frac{2}{N} \sum_{n=0}^{N-1} x_n \cos \frac{2\pi}{N} kn,$$

$$\hat{b}_k = \frac{2}{N} \sum_{n=0}^{N-1} x_n \sin \frac{2\pi}{N} kn.$$

$$\mathbf{C}_{\hat{\mathbf{a}}} = \sigma^2 [\mathbf{U}^T \mathbf{U}]^{-1} = \frac{2}{N} \sigma^2 \mathbf{I}$$

A becslők egymástól függetlenek.

$$y_n = \sum_{k=0}^{M-1} a_k x_{n-k} + w_k$$

3. Példa: A mozgó átlagoló (FIR szűrő), amikor a gerjesztés belépő függvény, tehát $x_n = 0$, ha $n < 0$:

$$\mathbf{z} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_{N-1} \end{bmatrix} = \begin{bmatrix} x_0 & 0 & \dots & \dots & 0 \\ x_1 & x_0 & \dots & \dots & 0 \\ x_2 & x_1 & x_0 & \dots & 0 \\ \vdots & \vdots & \vdots & \dots & 0 \\ x_{N-1} & x_{N-2} & x_{N-3} & \dots & x_{N-M} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_{M-1} \end{bmatrix} + \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{N-1} \end{bmatrix} = \mathbf{U}\mathbf{a} + \mathbf{w}$$

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

$$\hat{\mathbf{a}} \sim \mathcal{N}(\mathbf{a}, \sigma^2 (\mathbf{U}^T \mathbf{U})^{-1})$$

$$y_n = \sum_{k=0}^{M-1} a_k x_{n-k} + w_k$$

4. Példa: Mozgó-átlag (Moving Average: MA) paraméterek becslése. Most nem belépő függvényre:

$$\mathbf{U}^T \mathbf{U} = \begin{bmatrix} x_0 & x_1 & \dots & x_{N-1} \\ x_{-1} & x_0 & \dots & x_{N-2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1-M} & x_{2-M} & \dots & x_{N-M} \end{bmatrix} \begin{bmatrix} x_0 & x_{-1} & \dots & x_{1-M} \\ x_1 & x_0 & \dots & x_{2-M} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N-1} & x_{N-2} & \dots & x_{N-M} \end{bmatrix} = \sum_{n=0}^{N-1} \mathbf{X}_n \mathbf{X}_n^T = \sum_{n=0}^{N-1} \begin{bmatrix} x_n^2 & x_n x_{n-1} & \dots & x_n x_{n-M+1} \\ x_{n-1} x_n & x_{n-1}^2 & \dots & x_{n-1} x_{n-M+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-M+1} x_n & x_{n-M+1} x_{n-1} & \dots & x_{n-M+1}^2 \end{bmatrix}$$

$$\mathbf{U}^T \mathbf{z} = \sum_{n=0}^{N-1} \begin{bmatrix} x_n z_n \\ x_{n-1} z_n \\ \vdots \\ x_{n-M+1} z_n \end{bmatrix} \quad \text{ahol } \mathbf{X}_n^T = [x_n \ x_{n-1} \ \dots \ x_{n-M+1}]$$

$\hat{\mathbf{R}}_{xz}(k)$ „keresztkorreláció” becslés. Normálás!

$\hat{\mathbf{R}}_{xx}$ „autokorreláció” becslés. Normálás!

Ezzel:
$$\hat{\mathbf{a}} = \hat{\mathbf{R}}_{xx}^{-1} \hat{\mathbf{R}}_{xz}$$

5. Példa: Lineáris modell ismert \mathbf{s} jelkomponens esetén:

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

$\mathbf{z}' = \mathbf{z} - \mathbf{s}$
bevezetésével:

$$\hat{\mathbf{a}} = [\mathbf{U}^T \mathbf{U}]^{-1} \mathbf{U}^T (\mathbf{z} - \mathbf{s})$$

Fehér zaj esetén: $\mathbf{C}_{\hat{\mathbf{a}}} = \sigma^2 [\mathbf{U}^T \mathbf{U}]^{-1}$.

A egy ismeretlen konstans, r pedig egy ismert konstans:

$$x_n = A + r^n + w_n$$

$$\mathbf{z} = \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_{N-1} \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} A + \begin{bmatrix} 1 \\ r \\ \vdots \\ r^{N-1} \end{bmatrix} + \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{N-1} \end{bmatrix},$$

6. Példa: Lineáris modell színes Gauss zaj esetén:

$$\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{w}, \quad \mathbf{w} \sim \mathcal{N}(0, \mathbf{C}),$$

\mathbf{C} pozitív definit, ezért létezik olyan invertálható \mathbf{D} mátrix, amellyel $\mathbf{C}^{-1} = \mathbf{D}^T \mathbf{D}$.

$$E[(\mathbf{D}\mathbf{w})(\mathbf{D}\mathbf{w})^T] = E[\mathbf{D}\mathbf{w}\mathbf{w}^T \mathbf{D}^T] = \mathbf{D}\mathbf{C}\mathbf{D}^T = \mathbf{D}\mathbf{D}^{-1}(\mathbf{D}^T)^{-1}\mathbf{D}^T = \mathbf{I}$$

felhasználásával bevezethetünk egy transzformációt:

$$\mathbf{z}' = \mathbf{D}\mathbf{z} = \mathbf{D}\mathbf{U}\mathbf{a} + \mathbf{D}\mathbf{w} = \mathbf{U}'\mathbf{a} + \mathbf{w}', \quad \mathbf{w}' = \mathbf{D}\mathbf{w} \sim \mathcal{N}(0, \mathbf{I}).$$

$$\hat{A} = \frac{1}{N} \sum_{n=0}^{N-1} (x_n - r^n)$$

$$\text{var}\{\hat{A}\} = \frac{\sigma^2}{N}$$

$$\mathbf{z}' = \mathbf{Dz} = \mathbf{DUa} + \mathbf{Dw} = \mathbf{U}'\mathbf{a} + \mathbf{w}', \quad \mathbf{w}' = \mathbf{Dw} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}).$$

Ebből az ismeretlen paramétervektor kifejezhető:

$$\hat{\mathbf{a}} = [\mathbf{U}'^T \mathbf{U}']^{-1} \mathbf{U}'^T \mathbf{z}' = [\mathbf{U}^T \mathbf{D}^T \mathbf{DU}]^{-1} \mathbf{U}^T \mathbf{D}^T \mathbf{Dz} = [\mathbf{U}^T \mathbf{C}^{-1} \mathbf{U}]^{-1} \mathbf{U}^T \mathbf{C}^{-1} \mathbf{z},$$

$$\mathbf{C}_{\hat{\mathbf{a}}} = [\mathbf{U}^T \mathbf{C}^{-1} \mathbf{U}]^{-1}.$$

Megjegyzés: A házi feladatban színes zajt kell generálni. Ha \mathbf{w} fehér zaj, egységnyi szórással, akkor transzformáljuk: \mathbf{B} -vel $E[(\mathbf{Bw})(\mathbf{Bw})^T] = E[\mathbf{Bww}^T \mathbf{B}^T] = \mathbf{BB}^T = \mathbf{C}$ Egy lehetséges megoldás: **Cholesky felbontás**. Vagy: **mvnrnd()** multivariate normal random numbers

3.3.4. A legjobb lineáris torzítatlan becslő (Best Linear Unbiased Estimator, BLUE):

- Az MVU becslő nem mindig létezik vagy lehetetlenség megtalálni.
- Az adatok valószínűség sűrűségfüggvénye nem ismert.

A **BLUE** becslő egy **szuboptimális** becslő, amelyik:

- az adatok **lineáris** függvénye: $\hat{\mathbf{a}} = \mathbf{Hz}$;
- csak **torzítatlan** lehet: $E(\hat{\mathbf{a}}) = \mathbf{HE}(\mathbf{z}) = \mathbf{a}$;
- **minimalizálja** a becslő **varianciáját**;
- csak az adatok **átlagára** és **varianciájára** van szükség.

A BLUE meghatározása (skalár esetben):

A $z_k, k = 0, 1, \dots, N - 1$ adatokhoz az $\hat{a} = \sum_{k=0}^{N-1} h_k z_k = \mathbf{h}^T \mathbf{z}$

lineáris becslőt rendeljük, ahol $\mathbf{h} = \{h_0, h_1, \dots, h_{N-1}\}^T$.

A becslőtől elvárjuk a torzítatlanságot:

$$E(\hat{a}) = \sum_{k=0}^{N-1} h_k E(z_k) = a$$

Minimalizáljuk a varianciát:

$$\begin{aligned} \text{var}(\hat{a}) &= E\left\{(\hat{a} - E(\hat{a}))^2\right\} = E\left\{(\mathbf{h}^T \mathbf{z} - \mathbf{h}^T E(\mathbf{z}))^2\right\} = \\ &= E\left\{\mathbf{h}^T [\mathbf{z} - E(\mathbf{z})][\mathbf{z} - E(\mathbf{z})]^T \mathbf{h}\right\} = \mathbf{h}^T \mathbf{C} \mathbf{h}. \end{aligned}$$

1. Példa: Ismert jel amplitúdójának detektálása zajban: $z_k = as_k + w_k$

A lineáris becslő: $\hat{a} = \sum_{k=0}^{N-1} h_k z_k = \mathbf{h}^T \mathbf{z}$. Ez torzítatlan: $E(\hat{a}) = \mathbf{h}^T E(\mathbf{z}) = \mathbf{h}^T \mathbf{s} a = a$, ahol ehhez $\mathbf{h}^T \mathbf{s} = 1$ kell legyen, és $\mathbf{s} = \{s_0, s_1, \dots, s_{N-1}\}^T$. Minimalizálandó $\mathbf{h}^T \mathbf{C} \mathbf{h}$ a $\mathbf{h}^T \mathbf{s} = 1$ feltétel betartása mellett!

Ehhez a Lagrange multiplikátoros technikát használjuk. Keressük a következő kifejezés szélsőértékét: $J = \mathbf{h}^T \mathbf{C} \mathbf{h} + \lambda(\mathbf{h}^T \mathbf{s} - 1)$

$\frac{\partial J}{\partial \mathbf{h}} = 2\mathbf{C} \mathbf{h} + \lambda \mathbf{s} = \mathbf{0}$, ebből $\mathbf{h} = -\frac{\lambda}{2} \mathbf{C}^{-1} \mathbf{s}$, ezzel $\mathbf{h}^T \mathbf{s} = 1 = -\frac{\lambda}{2} \mathbf{s}^T \mathbf{C}^{-1} \mathbf{s}$, $-\frac{\lambda}{2} = \frac{1}{\mathbf{s}^T \mathbf{C}^{-1} \mathbf{s}}$, amit visszahelyettesítve \mathbf{h} kifejezésébe:

$\mathbf{h} = \frac{\mathbf{C}^{-1} \mathbf{s}}{\mathbf{s}^T \mathbf{C}^{-1} \mathbf{s}}$, és végül $\hat{a} = \mathbf{h}^T \mathbf{z}$ felhasználásával az optimális megoldás:

$$\hat{a} = \frac{\mathbf{s}^T \mathbf{C}^{-1} \mathbf{z}}{\mathbf{s}^T \mathbf{C}^{-1} \mathbf{s}},$$

$$\text{var}(\hat{a}) = \frac{1}{\mathbf{s}^T \mathbf{C}^{-1} \mathbf{s}}$$

A BLUE meghatározása (vektoros esetben):

$\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{w}$, ahol \mathbf{w} nulla várható értékű zaj, melynek kovariancia mátrixa \mathbf{C} , sűrűségfüggvénye tetszőleges,

akkor az \mathbf{a} paraméter **BLUE** becslője és a becslés kovariancia mátrixa: $\hat{\mathbf{a}} = (\mathbf{U}^T \mathbf{C}^{-1} \mathbf{U})^{-1} \mathbf{U}^T \mathbf{C}^{-1} \mathbf{z}$, $\mathbf{C}_{\hat{\mathbf{a}}} = (\mathbf{U}^T \mathbf{C}^{-1} \mathbf{U})^{-1}$

Megjegyzés: Ha a zaj Gauss eloszlású, akkor a BLUE egy MVU becslő.

2. Példa: DC szint zajban: $z_k = A + w_k$, w_k sűrűségfüggvényét nem ismerjük, csak a variáciáját: $var(w_k) = \sigma_k^2$.

$$\mathbf{U} = [1, 1, \dots, 1]^T,$$

$$\mathbf{a} = A.$$

A kovariancia mátrix: $\mathbf{C} = \begin{bmatrix} \sigma_0^2 & 0 & \dots & 0 \\ 0 & \sigma_1^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{N-1}^2 \end{bmatrix} \Rightarrow \mathbf{C}^{-1} = \begin{bmatrix} \frac{1}{\sigma_0^2} & 0 & \dots & 0 \\ 0 & \frac{1}{\sigma_1^2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{1}{\sigma_{N-1}^2} \end{bmatrix}$

$$\hat{\mathbf{a}} = (\mathbf{U}^T \mathbf{C}^{-1} \mathbf{U})^{-1} \mathbf{U}^T \mathbf{C}^{-1} \mathbf{z} = \left(\sum_{k=0}^{N-1} \frac{1}{\sigma_k^2} \right)^{-1} \sum_{k=0}^{N-1} \frac{z_k}{\sigma_k^2}$$

$$\mathbf{C}_{\hat{\mathbf{a}}} = (\mathbf{U}^T \mathbf{C}^{-1} \mathbf{U})^{-1} = \left(\sum_{k=0}^{N-1} \frac{1}{\sigma_k^2} \right)^{-1}$$

3.3.5. Maximum Likelihood (ML) becslők

Probléma, hogy **MVU becslők** esetlegesen léteznek vagy nem találhatók meg. A BLUE becslő **lineáris modellekre** szorítkozik.

A **Maximum Likelihood (ML) becslők** determinisztikus modellel leírt paraméterek esetén is használhatók. Tulajdonságaik:

- mindig használhatók, ha a valószínűségi sűrűség függvény (**csatornakarakterisztika**) ismert;
- nagy adatmérték esetén **optimálisak** (aszimptotikusan hatásosak, elérik a CRLB értéket);
- számítástechnikailag komplexek, numerikus módszerek használatát igénylik.

Likelihood függvény: az $f(\mathbf{z}; \mathbf{a})$ sűrűségfüggvény, ahol \mathbf{a} változó (nem paraméter)

ML becslő: \mathbf{a} azon értéke, amelyhez a likelihood függvény maximuma tartozik.

Eljárása: képezzük a $\ln f(\mathbf{z}; \mathbf{a})$ log-likelihood függvényt, és deriváljuk \mathbf{a} szerint, majd ezt nullával egyenlővé téve megoldjuk \mathbf{a} -ra.

Eredményül az $\hat{\mathbf{a}}_{ML}$ becslőt kapjuk.

1. Példa: Additív, Gauss eloszlású fehér zajjal terhelt DC szint mérése ismeretlen zaj variancia mellett: $z_n = A + w_n$.

Tegyük fel, hogy $A > 0$ és $\sigma^2 = A$. A valószínűség sűrűségfüggvény:

$$f(z; A) = \frac{1}{(2\pi A)^{\frac{N}{2}}} \exp \left[-\frac{1}{2A} \sum_{n=0}^{N-1} (z_n - A)^2 \right].$$

$$\frac{\partial \ln f(z; A)}{\partial A} = -\frac{N}{2A} + \frac{1}{A} \sum_{n=0}^{N-1} (z_n - A) + \frac{1}{2A^2} \sum_{n=0}^{N-1} (z_n - A)^2$$

CRLB?
Létezik MVU
becslő?

Az ML becslőt a derivált egyenlő nulla feltételből kapjuk:

$$\hat{A}_{ML} = -\frac{1}{2} + \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} z_n^2 + \frac{1}{4}}$$

3.3.6. Legkisebb négyzetes hibájú (LS) becslők

Nincs előzetes ismeretünk sem a mérendő paraméterről, sem a csatorna karakterisztikáról (a zajról).

Minden megfigyelést a következőképpen képzelünk el: $z_k = s_k(\mathbf{a}) + e_k$, ahol e_k a mérési és a modellezési hiba.

A cél az LS költség minimalizálása:

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

Nincs valószínűségi feltételezés csak egy determinisztikus jelmodell.

Ha a megfigyelési egyenlet lineáris: $\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{e}$, akkor explicit megoldás adható.

Feltételezzük, hogy az \mathbf{a} paraméter $\hat{\mathbf{a}}$ értéket vesz fel, és felállítjuk a megfigyelés modelljét: $\mathbf{U}\hat{\mathbf{a}}$.

$$J(\mathbf{a}, \hat{\mathbf{a}}) = (\mathbf{z} - \mathbf{U}\hat{\mathbf{a}})^T (\mathbf{z} - \mathbf{U}\hat{\mathbf{a}}) = \mathbf{z}^T \mathbf{z} - \mathbf{z}^T \mathbf{U}\hat{\mathbf{a}} - \hat{\mathbf{a}}^T \mathbf{U}^T \mathbf{z} + \hat{\mathbf{a}}^T \mathbf{U}^T \mathbf{U}\hat{\mathbf{a}} = \mathbf{z}^T \mathbf{z} - 2\hat{\mathbf{a}}^T \mathbf{U}^T \mathbf{z} + \hat{\mathbf{a}}^T \mathbf{U}^T \mathbf{U}\hat{\mathbf{a}}$$

melynek szélsőértékét (minimumát) keressük:

$$\left. \frac{\partial J(\mathbf{a}, \hat{\mathbf{a}})}{\partial \hat{\mathbf{a}}} \right|_{\hat{\mathbf{a}}=\hat{\mathbf{a}}_{LS}} = -2\mathbf{U}^T \mathbf{z} + 2\mathbf{U}^T \mathbf{U}\hat{\mathbf{a}} = 0$$

→

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

A minimális LS költség:

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

Megjegyzések: Súlyozott négyzetes kritériumot is használhatunk, ha bevezetünk egy \mathbf{Q} négyzetes súlyozó mátrixot, amivel:

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

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

Ha $\mathbf{Q} = \boldsymbol{\Sigma}_{nn}^{-1}$, akkor formálisan a Gauss-Markov becslőt kapjuk, tehát a GM becslő egy súlyozott legkisebb négyzetes hibájú becslő, ahol a súlyozást a megfigyelési zaj kovariancia mátrixának inverze adja.