
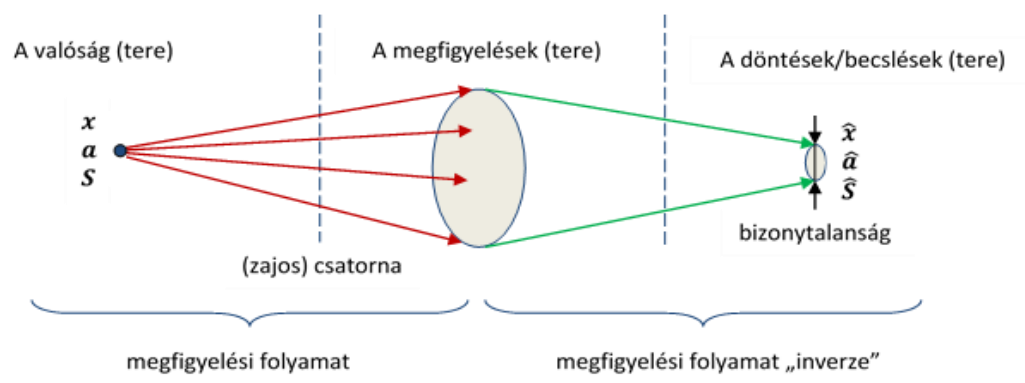




# Méréselmélet




3. fejezet: A becslélmélet alapjai

2021. március 3.




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

## 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

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



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

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

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



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:

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

Példa: DC szint zajban:



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

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

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

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

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

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

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

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

**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 (A<sup>2</sup>) „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  $\hat{\mathbf{a}}$  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** valószínűsűrség 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:  $x_n = a_0 + a_1 n + a_2 n^2 + \dots + a_p n^p + w_n$

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

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

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

**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:

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

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

$\hat{\mathbf{R}}_{xz}(k)$  „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:

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

$\mathbf{C}$  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:

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

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

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





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

Ebből az ismeretlen paramétervektor kifejezhető:

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

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

**Megjegyzés:** A házi feladatban színes zajt kell generálni. Ha  $\mathbf{w}$  fehér zaj, egységnyi szórással, akkor transzformáljuk:  $\mathbf{B}$ -vel  $E[(\mathbf{Bw})(\mathbf{Bw})^T] = E[\mathbf{Bww}^T \mathbf{B}^T] = \mathbf{B}\mathbf{B}^T = \mathbf{C}$  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:  $\hat{\mathbf{a}} = \mathbf{H}\mathbf{z}$ ;
- csak **torzítatlan** lehet:  $E(\hat{\mathbf{a}}) = \mathbf{H}E(\mathbf{z}) = \mathbf{a}$ ;
- **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:  $z_k = a s_k + w_k$

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  $\mathbf{Q} = \Sigma_{nn}^{-1}$ , 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.



