

4. A becslésmélet alapjai (folyt.)

Minimális átlagos négyzetes hibájú becslés:

$$\hat{a}_{MS} = \int_{-\infty}^{\infty} af(a|z)da, \quad (46)$$

azaz ezzel a kritériumfüggvénnyel a legjobb becslés az a posteriori várható érték.

Minimális átlagos abszolút hibájú becslés (skalár esetre bemutatva):

$$\hat{a}_{ABS} = f(a|z) \text{ mediánja.} \quad (50)$$

Maximum a posteriori (MAP) becslés:

$$\hat{a}_{MAP} = f(a|z) \text{ maximumhelye.} \quad (52)$$

Megjegyzések:

1. A Bayes becslések mindig az a posteriori sűrűségfüggvények alapján történnek.
2. Az MS becslés lineáris abban az alábbi értelemben:

Ha  $b = Aa + c$ , akkor  $\hat{b}_{MS} = A\hat{a}_{MS} + c$ , továbbá  $E\{a + b|z\} = E\{a|z\} + E\{b|z\} = \hat{a}_{MS} + \hat{b}_{MS}$ .

**Bayes becslő Gauss eloszlások esetén:** Tegyük fel, hogy a keresett  $a$  paraméter és a megfigyelési zaj Gauss eloszlásúak. Adott  $E\{a\} = \mu_a$ ,  $\text{cov}\{a, a\} = \Sigma_{aa}$ ,  $E\{n\} = 0$ ,  $\text{cov}\{n, n\} = \Sigma_{nn}$ . Ha "minden" Gauss eloszlású, akkor az a posteriori sűrűségfüggvény momentumai explicit formában megadhatók. Tegyük fel, hogy az additív zajjal terhelt megfigyelés az alábbi összefüggéssel írható le:

$$z = Ua + n, \quad (53)$$

ahol  $\dim a=p$ ,  $\dim z=q$ ,  $\dim U=q*p$ . Az  $U$  az ún. megfigyelési mátrix. Az explicit forma az a posteriori várható értékre:

$$\hat{a}_{MS} = \mu_{a|z} = \underbrace{\mu_a}_{\text{apriori\_ismeret}} + \underbrace{[U^T \Sigma_{nn}^{-1} U + \Sigma_{aa}^{-1}]^{-1} U^T \Sigma_{nn}^{-1} (z - U\mu_a)}_{\text{korrekció\_}z-U\mu_a\text{\_függvényében}} \quad (54)$$

**Megjegyzés:**  $\hat{a}_{MS} = \hat{a}_{ABS} = \hat{a}_{MAP}$ , mert az a posteriori sűrűségfüggvény Gauss.

**1. Példa:** Mérendő egy ellenállás értékét úgy, hogy ismert áram által ejtett feszültséget mérünk.  $N$  megfigyelést végzünk.  $U = IR + n$ . A megfigyelt értékek:  $z_k = a + n_k$ ,  $k=1, 2, \dots, N$ ,  $a$  az ismeretlen paraméter (ellenállás),  $n_k$  az additív zaj mintája. Tegyük fel, hogy az ellenállás (a gyártási sorozat egy eleme), és a megfigyelési zaj egyaránt Gauss eloszlású valószínűségi változóknak tekinthetők. A zaj megfigyelési értékei korrelálatlanok. Tegyük fel,

hogy ismert  $\mu_a$  és  $\sigma_a^2$ , a zaj várható értéke  $\mu_n = 0$ ,  $\text{cov}\{n_k, n_j\} = \sigma_n^2 \delta_{kj}$ , ahol  $\delta_{kj} = \begin{cases} 1 & \text{ha } k = j \\ 0 & \text{ha } k \neq j \end{cases}$ .

Vektoros alakban:  $z = Ua + n$ ,  $z^T = [z_1, z_2, \dots, z_N]$ ,  $n^T = [n_1, n_2, \dots, n_N]$ ,  $U^T = [1 \dots 1]$ ,  $\Sigma_{nn} = \sigma_n^2 I$ .

$$\hat{a}_{MS} = \mu_{a|z} = \mu_a + \left[ \frac{N}{\sigma_n^2} + \frac{1}{\sigma_a^2} \right]^{-1} \left( \frac{1}{\sigma_n^2} \sum_{k=1}^N z_k - \frac{N}{\sigma_n^2} \mu_a \right) = \mu_a + \frac{N \frac{\sigma_a^2}{\sigma_n^2}}{1 + N \frac{\sigma_a^2}{\sigma_n^2}} \left( \frac{1}{N} \sum_{k=1}^N z_k - \mu_a \right) = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=1}^N z_k}{1 + N \frac{\sigma_a^2}{\sigma_n^2}} \quad (55)$$

**Megjegyzések:**

1. Az (55) kifejezés alapján a becslés úgy interpretálható, mint egy predikciós-korrektíós formula, amelynek első tagja az a priori ismeret alapján egy jóslás: mekkora lehet a paraméter az előzetes ismeretek alapján, amit a többletinformáció (mérési eredmények) birtokában egy korrektíós tag egészít ki. Ez utóbbi a mért értékek átlaga és a paraméter várható értéke különbségével arányos. Az arányossági tényező  $N \frac{\sigma_a^2}{\sigma_n^2}$  értékének függvényében nulla és egy

közötti érték. Ha  $\sigma_a \ll \sigma_n$ , akkor  $\hat{a}_{MS} \cong \mu_a$ , ha  $\sigma_a \gg \sigma_n$  vagy  $N \rightarrow \infty$ , akkor  $\hat{a}_{MS} \cong \frac{1}{N} \sum_{k=1}^N z_k$ .

2. **A becslési hiba varianciája:** az a posteriori kovariancia:

$$\text{cov}\{a, a|z\} = \Sigma_{aa|z} = [U^T \Sigma_{mm}^{-1} U + \Sigma_{aa}^{-1}]^{-1} = \text{var}\{\tilde{a}\} = \frac{\sigma_a^2}{1 + N \frac{\sigma_a^2}{\sigma_n^2}}, \quad (56)$$

ahol  $\tilde{a} = \hat{a} - a$ . Az  $N \frac{\sigma_a^2}{\sigma_n^2}$  értékének függvényében  $\sigma_a^2$  és  $\frac{1}{N} \sigma_n^2$  közötti érték. Ha  $\sigma_a \ll \sigma_n$ , akkor  $\text{var}\{\tilde{a}\} \cong \sigma_a^2$ , ha  $\sigma_a \gg \sigma_n$  vagy  $N \rightarrow \infty$ , akkor  $\text{var}\{\tilde{a}\} \cong \frac{1}{N} \sigma_n^2$ .

3. **A becslés feltételesen torzított:** (nem hangzott el, de az anyag része!)

$$b(a) = E\{\hat{a}_{MS}|a\} - a = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=1}^N z_k}{1 + N \frac{\sigma_a^2}{\sigma_n^2}} - a = \frac{\mu_a - a}{1 + N \frac{\sigma_a^2}{\sigma_n^2}}. \quad (57)$$

**2. Példa:** Mérendő egy ismert jel ismeretlen amplitúdója.  $z_k = as_k + n_k$ ,  $k = 1, 2, \dots, N$ . Az ismeretlen  $a$  amplitúdó és  $n_k$  Gauss eloszlású, ismert várható értékkel és varianciával.  $E\{a\} = \mu_a$ ,  $\text{var}\{a\} = \sigma_a^2$ ,  $E\{n_k\} = 0$ ,  $\text{cov}\{n_i, n_j\} = \sigma_n^2 \delta_{ij}$ ,  $\text{cov}\{a, n_i\} = 0 \quad \forall i\text{-re, } \forall j\text{-re}$ .

Most használjuk a maximum a posteriori (MAP) becslés technikáját!

$$\left. \frac{\partial f(a|z)}{\partial a} \right|_{a=\hat{a}_{MAP}} = 0, \text{ illetve (37) felhasználásával } \left. \frac{\partial \ln f(z|a)}{\partial a} + \frac{\partial \ln f(a)}{\partial a} \right|_{a=\hat{a}_{MAP}} = 0. \quad (58)$$

Most  $f(a) = \frac{1}{\sqrt{2\pi}\sigma_a} e^{-\frac{(a-\mu_a)^2}{2\sigma_a^2}}$ ,  $f(z|a) = \frac{1}{(2\pi\sigma^2)^{\frac{N}{2}}} e^{-\frac{1}{2\sigma_n^2} \sum_{k=1}^N (z_k - as_k)^2}$ , amit az (58) összefüggés felhasználásával

$$\frac{\partial \ln f(a)}{\partial a} = -\frac{a - \mu_a}{\sigma_a^2}, \quad \frac{\partial \ln f(z|a)}{\partial a} = \frac{1}{\sigma_n^2} \sum_{k=1}^N s_k (z_k - as_k). \quad (59)$$

A két egyenletet egymással összeadva, és behelyettesítve az (58) összefüggésbe:

$$\frac{1}{\sigma_n^2} \sum_{k=1}^N s_k (z_k - a s_k) - \frac{a - \mu_a}{\sigma_a^2} \Big|_{a=\hat{a}_{MAP}} = 0, \text{ amiből } \hat{a}_{MAP} = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=1}^N s_k z_k}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=1}^N s_k^2} \quad (60)$$

**Megjegyzések:**

1. A MAP becslés alkalmazásával megspóroltuk az (54) mátrix-összefüggés használatát a becslő értékének meghatározásakor.

**2. A becslési hiba varianciája:**

$$\text{var}\{\tilde{a}\} = \frac{\sigma_a^2}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=1}^N s_k^2}, \quad (61)$$

3. Ha  $s_k=1, \forall k$ , akkor megkapjuk az előző példa eredményét.

4. Itt is azonosítható a döntéseméleti rész 2. feladatában említett „illesztett” szűrő.

5. Természetesen  $\hat{a}_{MAP} = \hat{a}_{MS}$ .

**Maximum likelihood (ML) becslő:** Nem ismerjük a mérendő mennyiség a priori valószínűség sűrűségfüggvényét. Ilyenkor azt feltételezzük, hogy ez a függvény „szélesen elterülő”, és ebből adódóan az a posteriori sűrűségfüggvény megegyezik a csatorna-karakterisztikával. Az optimális becslőt a csatorna-karakterisztika maximumához rendeljük:

$$\frac{\partial f(z|a)}{\partial a} \Big|_{a=\hat{a}_{ML}} = 0, \text{ ill. } \frac{\partial \ln f(z|a)}{\partial a} \Big|_{a=\hat{a}_{ML}} = 0 \quad (62)$$

**Megjegyzés:** A 16. ábrán látható viszonyokat a (37) összefüggés „szemszögéből” célszerű elemezni: az a posteriori sűrűségfüggvényt megadó összefüggés számlálója az ábrán látható két függvény szorzata. A szorzat maximumhelye láthatóan a (62) összefüggéssel megadható.

**Gauss-Markov (GM) becslő:** A maximum likelihood becslő speciális esete, amikor a megfigyelési zaj Gauss eloszlású, a megfigyelési egyenlet pedig lineáris.  $N$  dimenziós megfigyeléseket végzünk,  $n$  az  $N$  dimenziós zaj-vektor:

$$E\{n\} = 0, \text{ cov}\{n, n\} = \Sigma_{nn}, \quad f(n) = \frac{1}{(2\pi)^{\frac{N}{2}} |\Sigma_{nn}|^{\frac{1}{2}}} e^{-\frac{1}{2} n^T \Sigma_{nn}^{-1} n}, \quad (63)$$

ahol  $|\Sigma_{nn}|$  a  $\Sigma_{nn}$  mátrix determinánsát jelöli.

A megfigyelési egyenlet:  $z = Ua + n$ , amellyel a csatorna karakterisztika

$$f(z|a) = \frac{1}{(2\pi)^{\frac{N}{2}} |\Sigma_{nn}|^{\frac{1}{2}}} e^{-\frac{1}{2} (z-Ua)^T \Sigma_{nn}^{-1} (z-Ua)}, \quad (64)$$

melynek szélsőérték helye a

$$\frac{\partial \ln f(z|a)}{\partial a} = \frac{\partial}{\partial a} [(z-Ua)^T \Sigma_{nn}^{-1} (z-Ua)] \Big|_{a=\hat{a}_{GM}} = 0 \quad (65)$$

összefüggés alapján határozható meg. (65) alapján:

$U^T \Sigma_{nn}^{-1} Ua - U^T \Sigma_{nn}^{-1} z = 0$ , amiből

$$\hat{a}_{GM} = [U^T \Sigma_{nn}^{-1} U]^{-1} U^T \Sigma_{nn}^{-1} z, \quad (66)$$

ha  $[U^T \Sigma_m^{-1} U]^{-1}$  létezik.

**Megjegyzések:** (1) A (66) összefüggés  $\Sigma_{aa}^{-1} = 0$  (a „szórás végtelen”) helyettesítés mellett a Bayes esetből származtatható. (2) A Gauss-Markov becslő torzítatlan.

**Példa:** A  $z_k = a + n_k, k=1,2,\dots,N$ , független megfigyelések.  $E\{n_k\} = 0$ ;  $\text{cov}\{n_k, n_j\} = \sigma_n^2 \delta_{kj}$ . A

csatorna karakterisztika:  $f(z|a) = \frac{1}{(2\pi\sigma_n^2)^N} e^{-\frac{1}{2\sigma_n^2} \sum_{k=1}^N (z_k - a)^2}$ , amelynek maximumhelyénél kapjuk

az  $a$  paraméter Gauss-Markov becslője:  $\left. \frac{\partial \ln f(z|a)}{\partial a} \right|_{\hat{a}=\hat{a}_{ML}=\hat{a}_{GM}} = \frac{N}{\sigma_n^2} \left[ \frac{1}{N} \sum_{k=1}^N z_k - a \right] = 0$ ;

$$\boxed{\hat{a}_{ML} = \hat{a}_{GM} = \frac{1}{N} \sum_{k=1}^N z_k}, \quad (67)$$

azaz lineáris megfigyelési egyenlet, és Gauss eloszlású csatorna zaj esetén a legjobb (Gauss-Markov) becslő az egyszerű átlagolás.

**Legkisebb négyzetes hibájú (LS) becslők:** nincs előzetes ismeretünk sem a mérendő paraméterről, sem a csatorna karakterisztikáról (a zajról). Tegyük fel, hogy a megfigyelési egyenlet lineáris:  $z = Ua + n$ . Feltételezzük, hogy az  $a$  paraméter  $\hat{a}$  értéket vesz fel, és felállítjuk a megfigyelés modelljét:  $U\hat{a}$ . A megfigyelést ezzel összevetve keressük  $\hat{a}$  legjobb beállítását négyzetes hibafüggvény feltételezésével:

$$C(a, \hat{a}) = (z - U\hat{a})^T (z - U\hat{a}) = z^T z - z^T U\hat{a} - \hat{a}^T U^T z + \hat{a}^T U^T U \hat{a} = z^T z - 2 \hat{a}^T U^T z + \hat{a}^T U^T U \hat{a} \quad (68)$$

melynek szélsőértékét (minimumát) keressük:  $\left. \frac{\partial C(a, \hat{a})}{\partial \hat{a}} \right|_{\hat{a}=\hat{a}_{LS}} = 0$  feltétel vizsgálatával. (68)

deriválásával  $-2U^T z + 2U^T U \hat{a} = 0$ , amivel:

$$\boxed{\hat{a}_{LS} = [U^T U]^{-1} U^T z} \quad (69)$$

**Megjegyzések:**

1. A derivált helyességét egyszerűen ellenőrizhetjük, ha a (68) összefüggésben kijelölt mátrix-, ill. vektor-szorításokat kifejtjük, és azt követően a deriválást komponensenként végezzük el.

2. Általánosított/súlyozott négyzetes kritériumot is használhatunk, ha bevezetünk egy  $Q$  négyzetes súlyozó mátrixot:  $C(a, \hat{a}) = (z - U\hat{a})^T Q (z - U\hat{a})$ ,

amivel

$$\boxed{\hat{a}_{LS} = [U^T Q U]^{-1} U^T Q z}. \quad (71)$$

3. Ha  $Q = \Sigma_m^{-1}$ , akkor a (66) összefüggés szerinti Gauss-Markov becslőt kapjuk, tehát a GM becslő egy súlyozott legkisebb négyzetes hibájú becslő, ahol a súlyozást a megfigyelési zaj kovariancia mátrixának inverze adja.

**Példa:** Mozgó-átlag (Moving Average: MA) paraméterek becslése: Az  $\{y_n\}, n=1,2,\dots,N$ , diszkrét értéksorozat („kimenőjel”) elemei egy csúszó ablakon keresztül látható  $\{x_n\}$  diszkrét értékek („bemenőjel”) lineáris kombinációjaként állnak elő:

$$y_n = \sum_{k=0}^P a_k x_{n-k} . \quad (72)$$

Keresettek az  $\{a_k\}$  súlyozó együtthatók. A megfigyelés lineáris:  $z = Ua + n$ ;  $z_n = y_n + n_n$ ,  $n=1,2,\dots,N$ ,  $z^T = [z_1, z_2, \dots, z_N]$ ,  $a^T = [a_0, a_1, \dots, a_P]$ . A legkisebb négyzetes értelemben optimális paramétereket a (69) összefüggés adja.

Érdeemes megvizsgálni, hogy mi az információtartalma az  $[U^T U]^{-1}$  mátrixnak, illetve az  $U^T z$  vektornak. Ehhez írjuk fel az  $U^T U$  mátrixot diadikus szorzatok összegként:

$$\begin{bmatrix} x_1 & x_2 & \dots & x_N \\ x_0 & x_1 & \dots & x_{N-1} \\ \vdots & \vdots & \vdots & \vdots \\ x_{1-P} & x_{2-P} & \dots & x_{N-P} \end{bmatrix} \begin{bmatrix} x_1 & x_0 & \dots & x_{1-P} \\ x_2 & x_1 & \dots & x_{2-P} \\ \vdots & \vdots & \vdots & \vdots \\ x_N & x_{N-1} & \dots & x_{N-P} \end{bmatrix} = \sum_{n=1}^N x_n x_n^T = \sum_{n=1}^N \begin{bmatrix} x_n^2 & x_n x_{n-1} & \dots & x_n x_{n-P} \\ x_{n-1} x_n & x_{n-1}^2 & \dots & x_{n-1} x_{n-P} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n-P} x_n & x_{n-P} x_{n-1} & \dots & x_{n-P}^2 \end{bmatrix} \quad (73)$$

Figyeljük meg, hogy (73) egy olyan mátrix, amelynek elemei (alkalmas normálással kiegészítve) az  $\{x_n\}$  diszkrét értéksorozat autokorreláció értékeit becslik:

$$\hat{R}_{xx}(k-p) = \frac{1}{N} \sum_{n=1}^N x_{n-k} x_{n-p}, \quad k, p = 0, 1, \dots, P. \quad (74)$$

Hasonlóképpen felírva az  $U^T z$  vektort:

$$U^T z = \sum_{k=1}^N \begin{bmatrix} x_n z_n \\ x_{n-1} z_n \\ \vdots \\ x_{n-P} z_n \end{bmatrix} \quad (75)$$

(75) egy olyan vektor, amelynek elemei (alkalmas normálással kiegészítve) az  $\{x_n\}$  és  $\{z_n\}$  diszkrét értéksorozatok keresztkorreláció értékeit becslik:

$$\hat{R}_{xz}(k) = \frac{1}{N} \sum_{n=1}^N x_{n-k} z_n, \quad k = 0, 1, \dots, P. \quad (76)$$

Jelölje  $\hat{R}_{xx}$  a (74) összefüggés szerinti elemekből álló mátrixot,  $\hat{R}_{xz}$  pedig a (76) összefüggés szerinti elemekből álló vektort:

$$\hat{a}_{LS} = \hat{R}_{xx}^{-1} \hat{R}_{xz} \quad (77)$$

### Megjegyzés:

1. A (77) összefüggés természetesen mindössze egy formális átírás a példa szerinti viszonyok esetére, de a későbbiekben látni fogjuk ennek létjogosultságát.
2. Ezen a ponton formálisan befejezzük a becslélmélet alapjainak tárgyalását, de a folytatás, mint látni fogjuk, rendre „mérésekről”, azaz jelenségek, ill. azok paramétereinek és állapotainak megragadásáról szól, aminek konkrét eszközei tipikusan becslési eljárások lesznek.

### 5. Modellillesztés

**Regresszió-számítás:** függő és független változók közötti közvetlen, determinisztikus kapcsolat meghatározása, a modellillesztés egy speciális esete. A a modellezendő  $y = g(u, n)$  függvény kétfajta független változóval rendelkezik: az egyiket  $u(n)$  jelöli, amelyet ismerünk

és „kézben tudunk tartani”, a másik, amelyiket  $n(n)$  jelöli, amely ismeretlen, kézben nem tartható, tipikusan zajfolyamatnak elképzelt/modellezett folyamat.

**Megjegyzések:**

1. A továbbiakban az argumentumként szereplő kis „ $n$ ” nagyon gyakran az iterációs lépést azonosítja vagy diszkrét időindex, amely ekvivalens módon tényleges indexként is megjelenik időnként. Ennek megfelelően  $u(n) = u_n$ , ill.  $y(n) = y_n$  egyenértékűek.
2. A kis „ $n$ ” kettős használata senkit se zavarjon, a különbség egyértelmű: argumentumként, ill. indexként diszkrét („idő”) index, önállóan pedig zajfolyamatként interpretáljuk.

A modellezéshez egy általunk kézben tartott, tipikusan paraméterek segítségével módosítható („hangolható”)  $\hat{y} = \hat{g}(u)$  függvényt használunk. A cél egy olyan „beállítás” elérése, amely valamilyen értelemben optimális. Tipikusan négyzetes kritériumot használunk:

$$\varepsilon = E\{(y - \hat{y})^T (y - \hat{y})\} \quad (78)$$