





# Méréselmélet

- 2. fejezet: A döntéelmélet alapjai
- 3. fejezet: A becslélmélet alapjai

2021. február 17.

# 1.3. A mérési eljárás sajátosságai



Célunk az  $x(n)$  állapotvektor becslése.

$$x(n+1) - \hat{x}(n+1) = Ax(n) - A\hat{x}(n) - Ge(n) = (A - GC)(x(n) - \hat{x}(n)).$$


$\underbrace{\hspace{10em}}_{\varepsilon(n+1)} \quad \underbrace{\hspace{10em}}_{F} \quad \underbrace{\hspace{10em}}_{\varepsilon(n)}$

1.  $F = A - GC = 0$ . Ebben az esetben  $G = AC^{-1}$ .

2.  $F^N = (A - GC)^N = 0$ .  $x(N) - \hat{x}(N) = (A - GC)^N(x(0) - \hat{x}(0)) = 0$

3. Ha  $F^N = (A - GC)^N \neq 0$ , a hiba exponenciális jelleggel csökken.

**N lépéses konvergencia,  $\forall$  sajátérték nulla.**  
**„Majdnem minden rendszer megfigyelő.”**



$$H(z) = a_1z^{-1} + a_2z^{-2} + \dots + a_Nz^{-N} = \frac{a_N + a_{N-1}z + a_{N-2}z^2 + \dots + a_1z^{N-1}}{z^N}$$




valós idejű **kiszámíthatóság!**

**Megfigyelés zajos csatorna esetén:**  $y(n) = Cx(n) + \text{zaj}$   $\rightarrow$  véletlen  $\hat{x}(n+1), \varepsilon(n+1)$ .

$$E\left\{\sum_{k=0}^{N-1} \varepsilon_k^2(n)\right\} = E[\varepsilon^T(n)\varepsilon(n)] = \text{trace } E[\varepsilon(n)\varepsilon^T(n)] = \text{trace } P(n) \xrightarrow{n \rightarrow \infty} \min.$$


$\varepsilon(n+1) = F\varepsilon(n)$  helyett  $E[\varepsilon(n+1)\varepsilon^T(n+1)] = FE[\varepsilon(n)\varepsilon^T(n)]F^T = FP(n)F^T$

# 1.4. A zajos csatorna modellezése



## 2. A döntésmélet alapjai

**Példa:** detektálás radarral. Bináris vagy kéthipotézises döntés: eldöntendő a jelenlét vagy a jelen nem lét kérdése.



A csatorna zajos, ugyanarról a jelenségről rendre eltérő értékű megfigyeléseket kapunk. El kell döntenünk, hogy – egy vagy több megfigyelésre alapozva – a két lehetséges hipotézisből melyiket fogadjuk el:

$H_0$  hipotézis: az (ellenséges) objektum nincs jelen.

$H_1$  hipotézis: az (ellenséges) objektum jelen van.


**Lehetséges hibák:** Elfogadjuk  $H_0$ -t, holott  $H_1$  igaz. Ennek valószínűsége  $P_M$  (miss probability).

**Tévesztés valószínűsége**

Elfogadjuk  $H_1$ -t, holott  $H_0$  igaz. Ennek valószínűsége  $P_F$  (false alarm probability).

**Téves riasztás valószínűsége**

A döntéshez előzetesen felvesszük a megfigyelések hisztogramját, és abból közelítőleg előállítjuk az  $f(z|H_0)$  és  $f(z|H_1)$  **feltételes sűrűségfüggvényeket**. Ezeket **csatorna-karakterisztikáknak** is nevezzük.



Keressük a döntési küszöböt valamilyen **optimum kritérium** szerint.

Mivel a sűrűségfüggvények átlapolódnak, ezért a döntési küszöb meghatározása nem triviális.

Az ehhez alkalmazható konkrét stratégia a rendelkezésre álló **információ** függvénye.

**Kéthipotézises Bayes döntés:** Alkalmazási feltételek:


1. Ismerjük az ún. a priori valószínűségeket:  $H_0 \rightarrow P_0$  és  $H_1 \rightarrow P_1$ .
2. Ismerjük a csatornakarakterisztikákat:  $f(z|H_0)$  és  $f(z|H_1)$ .

Definiáljuk a költségeket:

$C_{ij}$  annak a költsége, hogy az  $i$ -edik hipotézist fogadtuk el, holott a  $j$ -edik igaz.

Értelmezzük a bekövetkezési valószínűségeket:

$P(H_i|H_j)$ , ahol az  $i$  index a feltételezett hipotézis, a  $j$  index pedig a bekövetkezett kimenetel azonosítója. ( $i$  és  $j$  most 0 vagy 1.)





Ha a küszöb alatti ( $Z_0$ ) tartományba esik a mért érték, akkor  $H_0$ -t fogadjuk el.

Ha a küszöb feletti ( $Z_1$ ) tartományba esik a mért érték, akkor  $H_1$ -t fogadjuk el.

**A cél:** a küszöb olyan beállítása, amely az átlagos **kockázatot** (risk)/**költséget** (cost) minimalizálja:

$$R = \underbrace{C_{00}P_0P(H_0|H_0)} + \underbrace{C_{10}P_0P(H_1|H_0)} + \underbrace{C_{01}P_1P(H_0|H_1)} + \underbrace{C_{11}P_1P(H_1|H_1)}$$

Annak költsége, hogy  $H_0$  következett be, és azt is fogadtuk el.

Annak költsége, hogy  $H_0$  következett be, és  $H_1$ -t fogadtuk el.

Annak költsége, hogy  $H_1$  következett be, és  $H_0$ -t fogadtuk el.

Annak költsége, hogy  $H_1$  következett be, és azt is fogadtuk el.

A kifejezés minimumát a döntési küszöb értékének alkalmas megválasztásával érjük el.

A bekövetkezési valószínűségek számítása:

$$P(H_i | H_j) = \int_{Z_i} f(z | H_j) dz,$$

$$R = C_{00}P_0 \int_{Z_0} f(z|H_0)dz + C_{10}P_0 \int_{Z_1} f(z|H_0)dz + C_{01}P_1 \int_{Z_0} f(z|H_1)dz + C_{11}P_1 \int_{Z_1} f(z|H_1)dz.$$

Mivel  $\int_{Z_1} f(z|H_0)dz = 1 - \int_{Z_0} f(z|H_0)dz$ , és  $\int_{Z_1} f(z|H_1)dz = 1 - \int_{Z_0} f(z|H_1)dz$ .

$$R = C_{10}P_0 + C_{11}P_1 + \underbrace{P_0(C_{00} - C_{10}) \int_{Z_0} f(z|H_0)dz}_{< 0} + \underbrace{P_1(C_{01} - C_{11}) \int_{Z_0} f(z|H_1)dz}_{> 0}$$


Tegyük fel, hogy  $C_{10} > C_{00}$ , és  $C_{01} > C_{11}$

Tekintsük a döntési küszöb helyét az összefüggésbeli egyváltozós integrál függvény független változójának!

Az átlagos kockázat minimuma a  $z$  változó azon értékénél (a keresett döntési küszöbértéknél) van, amelyre

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

A kiadódó döntési küszöbértéktől akár jobbra, akár balra eltérve az átlagos kockázat növekedni fog.



$$P_0(C_{10} - C_{00})f(z|H_0) = P_1(C_{01} - C_{11})f(z|H_1) \Rightarrow \Lambda(z) = \frac{f(z|H_1)}{f(z|H_0)} \Big|_{z_{k\ddot{u}sz\ddot{o}b}} = \frac{P_0(C_{10} - C_{00})}{P_1(C_{01} - C_{11})} = \eta$$

**valószínűség** ún. „likelihood” arány függvény

Ha az aktuálisan megfigyelt értéket behelyettesítjük a „likelihood” arány függvénybe, és ha  $\Lambda(z) > \eta$ , akkor a döntés  $H_1$ , ha  $\Lambda(z) < \eta$ , akkor a döntés  $H_0$ .

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

Ez az ún. Bayes döntési szabály vagy likelihood arány teszt.

**Megjegyzések:**

1. Ha a költségeket úgy választjuk meg, hogy  $\eta = \frac{P_0}{P_1}$  legyen, akkor a szabály  $P_1 f(z|H_1) > P_0 f(z|H_0)$  alakban írható.

**utólagos**

Ez megegyezik a  $P(H_1|z) > P(H_0|z)$  feltétellel, vagyis ilyenkor a döntést az *a posteriori* valószínűségek alapján hozhatjuk meg.

$P(H_0|z)$  annak a valószínűsége, hogy  $z$ -t mérve  $H_0$ ,  $P(H_1|z)$  pedig annak a valószínűsége, hogy  $z$ -t mérve  $H_1$  következett be.

Ezt a speciális esetet maximum a posteriori (MAP) döntésnek nevezzük.

2. Szokás a  $\lambda(z) = \ln \Lambda(z) > \ln \eta = \gamma$ , ún. log-likelihood arányt is használni.

**valószínűség**

**1. Példa:**

Konstans jel detektálása zajos csatornán keresztül: jelen van-e a jel a megfigyelésekben vagy nincsen?

Tegyük fel, hogy a megfigyelések független, Gauss eloszlású valószínűségi változók nulla várható értékkel, és  $\sigma_n^2$  varianciával.

A  **$H_0$  hipotézis** az, hogy a megfigyelés  $z_k = n_k$ , azaz **a jel nincsen jelen**, csak a zaj aktuális mintáját kapjuk.

A  **$H_1$  hipotézis** az, hogy a megfigyelés  $z_k = a + n_k$ , azaz **a jel jelen van**, a jel és a zaj aktuális mintájának összegét figyeltük meg.

$k = 0, 1, \dots, N - 1$ , azaz  $N$  mintát veszünk, és ezek együttes figyelembevételével döntünk. **Ekkor  $z$  egy  $N$  dimenziós vektor!**

A döntés során az együttes feltételes sűrűségfüggvényeket fogjuk használni, hiszen egyszerre veszünk figyelembe  $N$  mintát!

Minden mintáról tudjuk, hogy Gauss eloszlású. Mivel a minták függetlenek, az együttes feltételes sűrűség függvény az egyes feltételes sűrűségfüggvények szorzata lesz!



Egyetlen megfigyelés esetén a feltételes sűrűségfüggvények:

$$f(z|H_0) = \frac{1}{\sqrt{2\pi\sigma_n}} e^{-\frac{z_k^2}{2\sigma_n^2}}, \quad f(z|H_1) = \frac{1}{\sqrt{2\pi\sigma_n}} e^{-\frac{(z_k-a)^2}{2\sigma_n^2}}.$$


$$\Lambda(z) = \prod_{k=0}^{N-1} \frac{f(z_k|H_1)}{f(z_k|H_0)} = \prod_{k=0}^{N-1} \frac{e^{-\frac{(z_k-a)^2}{2\sigma_n^2}}}{e^{-\frac{z_k^2}{2\sigma_n^2}}} \underset{H_0}{\overset{H_1}{>}} \eta,$$

$$\ln \Lambda(z) = \lambda(z) = -\sum_{k=0}^{N-1} \frac{(z_k - a)^2}{2\sigma_n^2} + \sum_{k=0}^{N-1} \frac{z_k^2}{2\sigma_n^2} = \frac{1}{2\sigma_n^2} \sum_{k=0}^{N-1} -(z_k^2 - 2az_k + a^2 - z_k^2) = \frac{a}{\sigma_n^2} \sum_{k=0}^{N-1} z_k - \frac{Na^2}{2\sigma_n^2} \underset{H_0}{\overset{H_1}{>}} \ln \eta = \gamma$$

Átrendezve:

$$\frac{1}{N} \sum_{k=0}^{N-1} z_k \underset{H_0}{\overset{H_1}{>}} \frac{\sigma_n^2}{Na} \ln \eta + \frac{a}{2}$$

előfeldolgozás      küszöbérték



A döntőkészülék blokkvázlata

Ha  $\eta = 1$ , akkor  $\ln \eta = 0$

ekkor

$$\frac{1}{N} \sum_{k=0}^{N-1} z_k \underset{H_0}{\overset{H_1}{>}} \frac{a}{2}$$

**2. Példa:** Változó amplitúdójú jel detektálása zajos csatornán keresztül: jelen van-e a jel a megfigyelésekben vagy nincsen?

Tegyük fel, hogy a megfigyelések független, Gauss eloszlású valószínűségi változók nulla várható értékkel, és  $\sigma_n^2$  varianciával.

A  **$H_0$  hipotézis** az, hogy a megfigyelés  $z_k = n_k$ , azaz **a jel nincsen jelen**, csak a zaj aktuális mintáját kapjuk.


A  **$H_1$  hipotézis** az, hogy a megfigyelés  $z_k = a_k + n_k$ , azaz **a jel jelen van**, a jel és a zaj aktuális mintájának összegét figyeltük meg.

$k = 0, 1, \dots, N - 1$ , azaz  $N$  mintát veszünk, és ezek együttes figyelembevételével döntünk. Ekkor  $z$  egy  $N$  dimenziós vektor!

A döntés során az együttes feltételes sűrűségfüggvényeket fogjuk használni, hiszen egyszerre veszünk figyelembe  $N$  mintát!

Minden mintáról tudjuk, hogy Gauss eloszlású.

$$f(z|H_0) = \frac{1}{\sqrt{2\pi\sigma_n}} e^{-\frac{z_k^2}{2\sigma_n^2}}, \quad f(z|H_1) = \frac{1}{\sqrt{2\pi\sigma_n}} e^{-\frac{(z_k-a_k)^2}{2\sigma_n^2}}.$$





A megfigyelések függetlensége miatt a  $N$  megfigyelés együttes sűrűségfüggvénye az egyedi megfigyelések sűrűségfüggvényeinek szorzata.

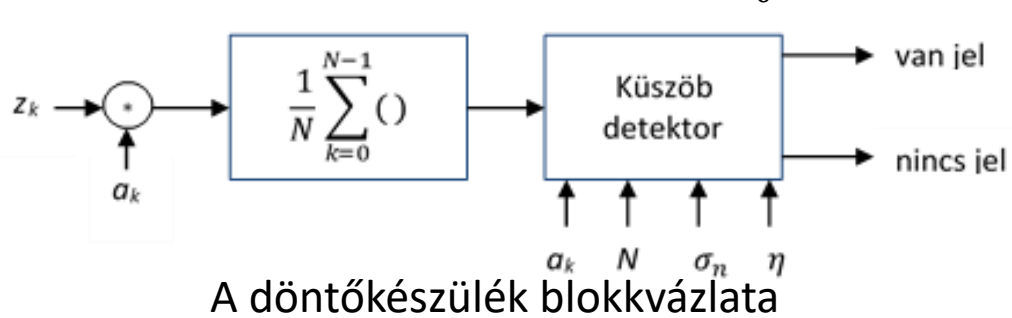
$$\Lambda(z) = \prod_{k=0}^{N-1} \frac{f(z_k | H_1)}{f(z_k | H_0)} = \prod_{k=0}^{N-1} \frac{e^{-\frac{(z_k - a_k)^2}{2\sigma_n^2}}}{e^{-\frac{z_k^2}{2\sigma_n^2}}} \begin{matrix} H_1 > \eta \\ H_0 < \eta \end{matrix}$$

$$\ln \Lambda(z) = \lambda(z) = - \sum_{k=0}^{N-1} \frac{(z_k - a_k)^2}{2\sigma_n^2} + \sum_{k=0}^{N-1} \frac{z_k^2}{2\sigma_n^2} = \frac{1}{\sigma_n^2} \sum_{k=0}^{N-1} z_k a_k - \frac{1}{2\sigma_n^2} \sum_{k=0}^{N-1} a_k^2 \begin{matrix} H_1 > \ln \eta \\ H_0 < \ln \eta \end{matrix} = \gamma$$

Átrendezve:  $\frac{1}{N} \sum_{k=0}^{N-1} a_k z_k \begin{matrix} H_1 > \frac{\sigma_n^2}{N} \ln \eta \\ H_0 < \frac{\sigma_n^2}{N} \ln \eta \end{matrix} + \frac{1}{2N} \sum_{k=0}^{N-1} a_k^2$

előfeldolgozás      küszöbérték

„illesztett szűrő”



Ha a minták egyformák, akkor az előző eredményt kapjuk.

**3. példa:** Véletlen amplitúdójú jel detektálása zajos csatornán keresztül: jelen van-e a jel a megfigyelésekben vagy nincsen?

Tegyük fel, hogy a jel és a zaj egyaránt időben diszkrét, stacionárius sztochasztikus fehér zaj folyamatok, Gauss eloszlással, nulla várható értékkel, és  $\sigma_a^2$ , ill.  $\sigma_n^2$  varianciával.

- A  $H_0$  hipotézis az, hogy a megfigyelés  $z_k = n_k$ , azaz **a jel nincsen jelen**, csak a zaj aktuális mintáját kapjuk.
  - A  $H_1$  hipotézis az, hogy a megfigyelés  $z_k = a_k + n_k$ , azaz **a jel jelen van**, a jel és a zaj aktuális mintájának összegét figyeltük meg.
- $k = 0, 1, \dots, N - 1$ , azaz összesen  $N$  mintát figyelünk meg egyszerre.
- A döntés során az együttes feltételes sűrűségfüggvényeket fogjuk használni.



$$f(z|H_0) = \frac{1}{\sqrt{2\pi}\sigma_n} e^{-\frac{z_k^2}{2\sigma_n^2}}, \quad f(z|H_1) = \frac{1}{\sqrt{2\pi}\sqrt{\sigma_a^2 + \sigma_n^2}} e^{-\frac{z_k^2}{2(\sigma_a^2 + \sigma_n^2)}}.$$

$$\Lambda(z) = \prod_{k=0}^{N-1} \frac{f(z_k|H_1)}{f(z_k|H_0)} = \prod_{k=0}^{N-1} \left[ \frac{\sigma_n}{\sqrt{\sigma_a^2 + \sigma_n^2}} e^{-\frac{z_k^2}{2(\sigma_a^2 + \sigma_n^2)}} \right] \begin{matrix} H_1 \\ > \eta \\ H_0 \\ < \end{matrix}$$


$$\ln \Lambda(z) = \frac{N}{2} \ln \frac{\sigma_n^2}{\sigma_a^2 + \sigma_n^2} - \sum_{k=0}^{N-1} \frac{z_k^2}{2(\sigma_a^2 + \sigma_n^2)} + \sum_{k=0}^{N-1} \frac{z_k^2}{2\sigma_n^2} = \frac{\sigma_a^2}{2\sigma_n^2(\sigma_a^2 + \sigma_n^2)} \sum_{k=0}^{N-1} z_k^2 + \frac{N}{2} \ln \frac{\sigma_n^2}{\sigma_a^2 + \sigma_n^2} \begin{matrix} H_1 \\ > \\ H_0 \\ < \end{matrix} \ln \eta = \gamma$$

Átrendezve:


$$\frac{1}{N} \sum_{k=0}^{N-1} z_k^2 \begin{matrix} H_1 \\ > \\ H_0 \\ < \end{matrix} \frac{2\sigma_n^2(\sigma_a^2 + \sigma_n^2)}{\sigma_a^2} \left[ \frac{1}{2} \ln \frac{\sigma_a^2 + \sigma_n^2}{\sigma_n^2} + \frac{1}{N} \ln \eta \right]$$

előfeldolgozás

küszöbérték

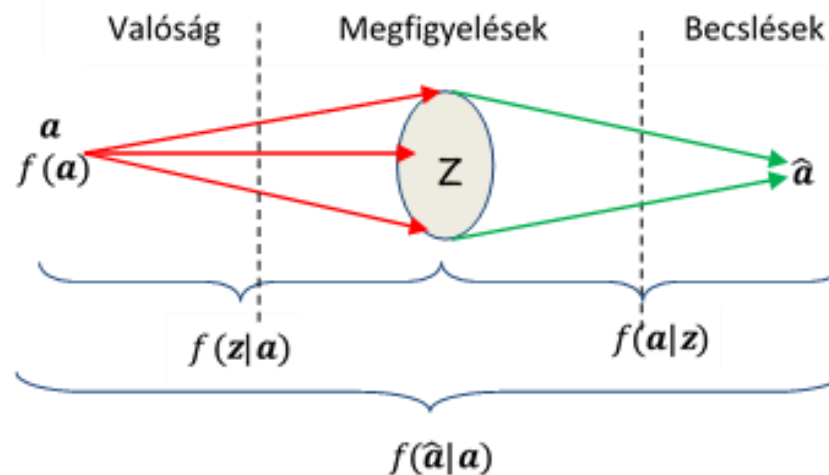


A döntőkészülék blokkvázlata



Döntési tartományok

### 3. A becslésméлет alapjai




A cél az  $\mathbf{a}$  paraméter(vektor)  $\hat{\mathbf{a}}$  becslőjének meghatározása az ábrán látható előzetesen ismert (és az azokból származtatott) sűrűségfüggvények ismeretében.





### 3. A becslésmélet alapjai




A cél az  $\mathbf{a}$  paraméter(vektor)  $\hat{\mathbf{a}}$  becslőjének meghatározása az ábrán látható előzetesen ismert (és az azokból származtatott) sűrűségfüggvények ismeretében.

$\mathbf{a}$  véletlen (bizonytalan) érték  $\rightarrow$  hisztogram  $\rightarrow f(\mathbf{a})$  csatorna karakterisztika  
 $\mathbf{a}$  fix érték  $\rightarrow \mathbf{z}$  véletlen (bizonytalan) érték  $\rightarrow$  hisztogram  $\rightarrow f(\mathbf{z}|\mathbf{a})$

Mi a megfigyelt értéket/érték-halmazt ( $\mathbf{z}$ ) ismerjük!

Vajon milyen értékű és gyakoriságú  $\mathbf{a}$  eredményezhetett ilyen  $\mathbf{z}$  értéket?  $\rightarrow$  hisztogram  $\rightarrow f(\mathbf{a}|\mathbf{z})$  csatorna karakterisztika „inverze”

Amit mi keresünk:  $\hat{\mathbf{a}}$  becslő, és annak „minősítése”.



1. **Feltételes várhatóérték:**  $E\{\hat{\mathbf{a}}|\mathbf{a}\} = \int_{-\infty}^{\infty} \hat{\mathbf{a}} f(\hat{\mathbf{a}}|\mathbf{a}) d\hat{\mathbf{a}}$

2. **Feltételes kovariancia mátrix:**  $cov\{\hat{\mathbf{a}}, \hat{\mathbf{a}}|\mathbf{a}\} = E\{(\hat{\mathbf{a}} - E(\hat{\mathbf{a}}|\mathbf{a}))(\hat{\mathbf{a}} - E(\hat{\mathbf{a}}|\mathbf{a}))^T | \mathbf{a}\}$

3. **Feltételes torzítás (bias):**  $b(\mathbf{a}) = E\{\hat{\mathbf{a}}|\mathbf{a}\} - \mathbf{a}$

4. **Átlagos négyzetes hiba (Mean Square Error (MSE)) mátrix:**  $E\{(\hat{\mathbf{a}} - \mathbf{a})(\hat{\mathbf{a}} - \mathbf{a})^T | \mathbf{a}\} = cov\{\hat{\mathbf{a}}, \hat{\mathbf{a}}|\mathbf{a}\} + b(\mathbf{a})b^T(\mathbf{a})$

Ha ismert az  $f(\mathbf{a})$  valószínűség-sűrűségfüggvény, akkor definiálható:

5. **Feltétel nélküli várható érték:**  $E(\hat{\mathbf{a}}) = E\{E\{\hat{\mathbf{a}}|\mathbf{a}\}\}$  6. **Feltétel nélküli kovariancia mátrix:**  $cov\{\hat{\mathbf{a}}, \hat{\mathbf{a}}\} = E\{cov\{\hat{\mathbf{a}}, \hat{\mathbf{a}}|\mathbf{a}\}\}$

#### 3.1. Bayes becslők



Az ismeretlen (mérendő) paramétert **valószínűségi változóként** modellezzük. Az egyszerűség kedvéért a paraméter legyen skalár.


Feltételezzük, hogy ismert a megfigyelt paraméter **sűrűségfüggvénye:**  $f(a)$ , és a **csatorna karakterisztikája:**  $f(z|a)$ .

A **Bayes szabály** felhasználásával előállítható az  $f(a|z)$  ún. *a posteriori* (utólagos) sűrűségfüggvény:

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

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





Ha a megfigyelések tartalmaznak a paraméterre vonatkozó információt, az *a posteriori* sűrűségfüggvény a konkrét paraméter-értékek egy szűkebb környezetére terjed ki.

Az *a posteriori* sűrűségfüggvény segítségével határozzuk meg az ismeretlen paraméter (vektor) „legjobb” becslőjét. Ehhez értelmezünk kell a „legjobb” fogalmát alkalmas **költségfüggvényeken** keresztül:

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

A **Bayes költség** ennek a minimuma:

$$R_B = \min_{\hat{a}} R(\hat{a}, a) = \min_{\hat{a}} E\{C(\hat{a}, a)\}.$$

Itt  $C(\hat{a}, a)$  az ún. **költségfüggvény**, vagy **kockázatfüggvény**, vagy **kritériumfüggvény**, vagy **hibafüggvény**, vagy **illesztési függvény**.

I. **Négyzetes kritérium** (vektor paraméter megengedett):




$$C(\hat{a}, a) = \sum_{i=1}^m (\hat{a}_i - a_i)^2 = (\hat{a} - a)^T (\hat{a} - a)$$

II. **Abszolút kritérium** (vektor paraméter megengedett):

$$C(\hat{a}, a) = \sum_{i=1}^m |\hat{a}_i - a_i|$$

III. **Maximum a posteriori kritérium** (vektor paraméter megengedett):

$$C(\hat{a}, a) = \begin{cases} 0 & \text{ha} \\ 1 & \text{egyébként} \end{cases} \quad |\hat{a}_i - a_i| \leq \frac{\Delta}{2} \quad \forall i - re$$



### 3.1.1. Minimális átlagos négyzetes hibájú becslés

$$R(\hat{a}, a) = E\{(\hat{a} - a)^T (\hat{a} - a)\} = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{\infty} (\hat{a} - a)^T (\hat{a} - a) f(a|z) da \right] f(z) dz = \int_{-\infty}^{\infty} g(\hat{a}) f(z) dz$$

felhasználjuk, hogy  $f(a, z) = f(a|z)f(z)$ .

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

Csak ez függ  $\hat{a}$ -tól, ezért elég ennek a minimumát keresni!



$$g(\hat{a}) = \int_{-\infty}^{\infty} (\hat{a} - a)^T (\hat{a} - a) f(a|z) da \quad \text{minimumának feltétele} \quad \frac{\partial}{\partial \hat{a}} \int_{-\infty}^{\infty} (\hat{a} - a)^T (\hat{a} - a) f(a|z) da \Big|_{\hat{a} = \hat{a}_{MS}} = 0$$

Mivel  $\frac{\partial}{\partial \hat{a}} (\hat{a} - a)^T (\hat{a} - a) = 2(\hat{a} - a) \rightarrow \int_{-\infty}^{\infty} \hat{a}_{MS} f(a|z) da = \hat{a}_{MS} = \int_{-\infty}^{\infty} a f(a|z) da$

A legjobb becslés az  $a$  posteriori várható érték!

### 3.1.2. Minimális átlagos abszolút hibájú becslés

Skalár esetre bemutatva:

$$R(\hat{a}, a) = E\{|\hat{a} - a|\} = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{\hat{a}} (\hat{a} - a) f(a|z) da - \int_{\hat{a}}^{\infty} (\hat{a} - a) f(a|z) da \right] f(z) dz = \int_{-\infty}^{\infty} g(\hat{a}) f(z) dz$$

Itt is elég  $g(\hat{a})$  minimumát megkeresni:

$$\frac{\partial}{\partial \hat{a}} \left[ \int_{-\infty}^{\hat{a}} (\hat{a} - a) f(a|z) da - \int_{\hat{a}}^{\infty} (\hat{a} - a) f(a|z) da \right] \Big|_{\hat{a} = \hat{a}_{ABS}} = 0 \rightarrow \int_{-\infty}^{\hat{a}_{ABS}} f(a|z) da = \int_{\hat{a}_{ABS}}^{\infty} f(a|z) da$$

$g(\hat{a})$

$\hat{a}_{ABS} = f(a|z)$  mediánja.

### 3.1.3. Maximum a posteriori (MAP) becslés

$$g(\hat{a}) = \int_{-\infty}^{\hat{a} - \frac{\Delta}{2}} f(a|z) da + \int_{\hat{a} + \frac{\Delta}{2}}^{\infty} f(a|z) da = 1 - \int_{\hat{a} - \frac{\Delta}{2}}^{\hat{a} + \frac{\Delta}{2}} f(a|z) da$$

Ha  $\Delta$  kicsi, de  $\Delta \neq 0$ , akkor az optimum az  $a$  posteriori sűrűségfüggvény maximumhelye

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

#### Megjegyzések:

1. A Bayes becslések **mindig** az  $a$  posteriori sűrűségfüggvények alapján történnek.
2. Vektor paraméterre **általánosíthatók**.
3. Az MS becslés **lineáris** abban az alábbi értelemben:

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



### 3.1.4. Bayes becslő Gauss eloszlások esetén

Tegyük fel, hogy a keresett  $a$  paraméter és a megfigyelési zaj **Gauss eloszlásúak!**

A paraméter lehet **vektor**, és lehet, hogy a kiértékeléseknél **több megfigyelést** veszünk **egyidejűleg** figyelembe.

Adott  $E\{\mathbf{a}\} = \boldsymbol{\mu}_a$ ,  $cov\{\mathbf{a}, \mathbf{a}\} = \boldsymbol{\Sigma}_{aa} \rightarrow$  Gauss eloszlás esetén „mindent” tudunk  $\mathbf{a}$ -ról!

$E\{\mathbf{n}\} = 0$ ,  $cov\{\mathbf{n}, \mathbf{n}\} = \boldsymbol{\Sigma}_{nn} \rightarrow$  Gauss eloszlás esetén „mindent” tudunk **a csatornáról!**

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:

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

A megfigyelés  
modellje lineáris!

Itt  $\dim \mathbf{a} = p$ ,  $\dim \mathbf{z} = q$ ,  $\dim \mathbf{U} = q * p$ . Az  $\mathbf{U}$  az ún. **megfigyelési mátrix**.

Az  $a$  posteriori várható érték explicit formája ilyen körülmények között:

$$\hat{\mathbf{a}}_{MS} = \boldsymbol{\mu}_{a|z} = \underbrace{\boldsymbol{\mu}_a}_{\text{apriori ismeret}} + \underbrace{[\mathbf{U}^T \boldsymbol{\Sigma}_{nn}^{-1} \mathbf{U} + \boldsymbol{\Sigma}_{aa}^{-1}]^{-1} \mathbf{U}^T \boldsymbol{\Sigma}_{nn}^{-1} (\mathbf{z} - \mathbf{U}\boldsymbol{\mu}_a)}_{\text{korrekció } \mathbf{z} - \mathbf{U}\boldsymbol{\mu}_a \text{ függvényében}}$$

Az  $a$  posteriori kovariancia explicit formája ilyen körülmények között:

$$cov\{\mathbf{a}, \mathbf{a} | \mathbf{z}\} = \boldsymbol{\Sigma}_{aa|z} = [\mathbf{U}^T \boldsymbol{\Sigma}_{nn}^{-1} \mathbf{U} + \boldsymbol{\Sigma}_{aa}^{-1}]^{-1}$$

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

**1. Példa:** Mérendő egy ellenállás értékét úgy, hogy ismert áram által ejtett feszültséget mérünk.  $N$  megfigyelést végzünk.


“ $U = IR + \text{zaj}$ ” a modellünk. A megfigyelt értékek:  $z_k = a + n_k$ ,  $k = 0, 1, \dots, N - 1$ ,  $a$  az ismeretlen paraméter (ellenállás),  $n_k$  az additív zaj mintája.

Tegyük fel, hogy az **ellenállás értéke** és a **megfigyelési zaj** egyaránt **Gauss eloszlású** valószínűségi változóknak tekinthetők.

A zaj megfigyelési értékei **korrelálatlanok**. Tegyük fel, hogy **ismert**  $\mu_a$  és  $\sigma_a^2 \rightarrow$  az ismeretlen paraméter jellemzése.

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

Vektoros alakban:  $\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{n}$   $\mathbf{z}^T = [z_0, z_2, \dots, z_{N-1}]$ ,  $\mathbf{n}^T = [n_0, n_2, \dots, n_{N-1}]$ ,  $\mathbf{U} = [1 \quad 1 \quad \dots \quad 1]^T$ ,  $\boldsymbol{\Sigma}_{nn} = \sigma_n^2 \mathbf{I}$



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

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

$$\hat{a}_{MS} = \mu_{a|z} = \mu_a + \left[ \frac{N}{\sigma_n^2} + \frac{1}{\sigma_a^2} \right]^{-1} \left( \frac{1}{\sigma_n^2} \sum_{k=0}^{N-1} z_k - \frac{N}{\sigma_n^2} \mu_a \right) = \mu_a + \frac{N \frac{\sigma_a^2}{\sigma_n^2}}{1 + N \frac{\sigma_a^2}{\sigma_n^2}} \left( \frac{1}{N} \sum_{k=0}^{N-1} z_k - \mu_a \right) = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} z_k}{1 + N \frac{\sigma_a^2}{\sigma_n^2}}$$

Ha  $\sigma_a \ll \sigma_n$ , akkor  $\hat{a}_{MS} \cong \mu_a$ ,

ha  $\sigma_a \gg \sigma_n$  vagy  $N \rightarrow \infty$ , akkor  $\hat{a}_{MS} \cong \frac{1}{N} \sum_{k=0}^{N-1} z_k$ .

előzetes ismeret

minták átlaga

predikció



korrekció

a méréssel szerzett információ alapján.

A becslési hiba **varianciája**: az  $a$  posteriori kovariancia:

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

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  $\text{var}\{\tilde{a}\} \cong \frac{1}{N} \sigma_n^2$ .

$$\tilde{a} = \hat{a} - a$$

A becslés feltételesen torzított:  $b(a) = E\{\hat{a}_{MS}|a\} - a =$

$$= E \left\{ \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} z_k}{1 + N \frac{\sigma_a^2}{\sigma_n^2}} \right\} - a = \frac{\mu_a - a}{1 + N \frac{\sigma_a^2}{\sigma_n^2}} \quad \text{Itt felhasználtuk, hogy } E\{z_k\} = a.$$

**2. Példa:** Mérendő egy ismert jel ismeretlen amplitúdója.

$z_k = a s_k + n_k$ ,  $k = 0, 1, \dots, N-1$ . Az ismeretlen  $a$  amplitúdó és  $n_k$  Gauss eloszlású.  $E\{a\} = \mu_a$ ,  $\text{var}\{a\} = \sigma_a^2$ ,

$E\{n_k\} = 0$ ,  $\text{cov}\{n_i, n_j\} = \sigma_n^2 \delta_{ij}$ ,  $\text{cov}\{a, n_i\} = 0 \quad \forall i$ -re,  $\forall j$ -re.

Most használjuk a **maximum a posteriori (MAP)** becslést!

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


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

Most  $f(a) = \frac{1}{\sqrt{2\pi}\sigma_a} e^{-\frac{(a-\mu_a)^2}{2\sigma_a^2}} \rightarrow \frac{\partial \ln f(a)}{\partial a} = -\frac{a-\mu_a}{\sigma_a^2}$

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

$$\frac{\partial \ln f(z)}{\partial a} = 0$$

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



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

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

$$\frac{\partial \ln f(a)}{\partial a} = -\frac{a - \mu_a}{\sigma_a^2} \quad \frac{\partial \ln f(\mathbf{z}|a)}{\partial a} = \frac{1}{\sigma_n^2} \sum_{k=0}^{N-1} s_k (z_k - a s_k)$$

$$= 0 \rightarrow \hat{a}_{MAP} = \frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k z_k}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2}$$

$$\text{var}\{\tilde{a}\} = \frac{\sigma_a^2}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2}$$

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

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

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

