



Méréselmélet

- 2. fejezet: A döntéselmélet alapjai
- 3. fejezet: A becsléselmélet alapjai

2022. február 23.

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.



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

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 $P_1 f(z|H_1) \begin{matrix} > \\ < \end{matrix} P_0 f(z|H_0)$ alakban írható.

utólagos

Ez megegyezik a $P(H_1|z) \begin{matrix} > \\ < \end{matrix} P(H_0|z)$ 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 $\lambda(z) = \ln \Lambda(z) \begin{matrix} > \\ < \end{matrix} \ln \eta = \gamma$, 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 σ_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 σ_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.

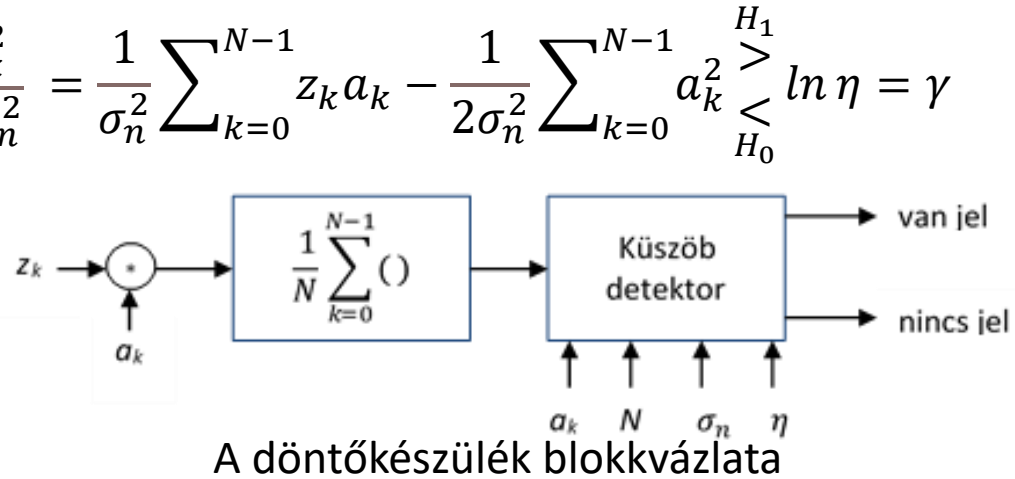
$$\Lambda(z) = \prod_{k=0}^{N-1} \frac{f(z_k | H_1)}{f(z_k | H_0)} = \prod_{k=0}^{N-1} \frac{e^{-\frac{(z_k - a_k)^2}{2\sigma_n^2}}}{e^{-\frac{z_k^2}{2\sigma_n^2}}} \begin{matrix} H_1 > \eta \\ H_0 < \eta \end{matrix}$$

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

Átrendezve:

$$\underbrace{\frac{1}{N} \sum_{k=0}^{N-1} a_k z_k}_{\text{előfeldolgozás}} \begin{matrix} H_1 > \frac{\sigma_n^2}{N} \ln \eta \\ H_0 < \frac{\sigma_n^2}{N} \ln \eta \end{matrix} + \underbrace{\frac{1}{2N} \sum_{k=0}^{N-1} a_k^2}_{\text{küszöbérték}}$$

„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 σ_a^2 , ill. σ_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.

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

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


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

Átrendezve:


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

előfeldolgozás

küszöbérték



A döntőkészülék blokkvázlata




Döntési tartományok

Megjegyzések:

1. A kéthipotézises Bayes döntés általánosítható több hipotézis esetre
2. Ha az apriori valószínűségek változnak vagy nem ismertek, akkor egyéb megfontolásokat kell tennünk a küszöbértékek meghatározása érdekében.

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

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”



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):** $b(\mathbf{a}) = E\{\hat{\mathbf{a}}|\mathbf{a}\} - \mathbf{a}$

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

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:

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





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:

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

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 Δ 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!

$E\{\mathbf{n}\} = \mathbf{0}$, $cov\{\mathbf{n}, \mathbf{n}\} = \boldsymbol{\Sigma}_{nn} \rightarrow$ 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** μ_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: $\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{n}$ $\mathbf{z}^T = [z_0, z_1, \dots, z_{N-1}]$, $\mathbf{n}^T = [n_0, n_1, \dots, n_{N-1}]$, $\mathbf{U} = [1 \quad 1 \quad \dots \quad 1]^T$, $\boldsymbol{\Sigma}_{nn} = \sigma_n^2 \mathbf{I}$

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

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

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

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. $E\{a\} = \mu_a$, $\text{var}\{a\} = \sigma_a^2$,

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

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

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

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

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

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

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

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

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

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

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

Itt is azonosítható a döntéseméleti rész 2. feladatában említett „illesztett” szűrő. Természetesen $\hat{a}_{MAP} = \hat{a}_{MS}$.

Megjegyzés: A variancia kifejezésének bizonyítása:

$$var\{\tilde{a}\} = E\{(\hat{a} - a)^2\} = E\left\{ \left(\frac{\mu_a + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k z_k - a - a \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2} \right)^2 \right\} = \frac{E\left\{ \left((\mu_a - a) + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k (z_k - a s_k) \right)^2 \right\}}{\left(1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2 \right)^2}$$

Itt $E\{(\mu_a - a)^2\} = \sigma_a^2$
 $E\{(\mu_a - a)(z_k - a s_k)\} = 0$
 mert $E\{n_k\} = 0$, és
 $E\{a n_k\} = 0, \forall k$

A második tag négyzete:

$$E\left\{ \left(\frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k (z_k - a s_k) \right)^2 \right\} = \frac{\sigma_a^4}{\sigma_n^4} \sum_{k=0}^{N-1} s_k^2 \sum_{k=0}^{N-1} s_k^2 \text{ mert } E\{n_k n_j\} = 0, k \neq j.$$


Ezzel:

$$var\{\tilde{a}\} = E\{(\hat{a} - a)^2\} = \frac{\sigma_a^2 + \frac{\sigma_a^4}{\sigma_n^4} \sum_{k=0}^{N-1} s_k^2}{\left(1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2 \right)^2} = \frac{\sigma_a^2}{1 + \frac{\sigma_a^2}{\sigma_n^2} \sum_{k=0}^{N-1} s_k^2}$$

3.2. Maximum Likelihood (ML) becslő

Kiindulásunk, hogy **nem ismerjük** a mérendő mennyiség a priori valószínűségi sűrűség függvényét. 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:



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

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

3.2.1. Gauss-Markov (GM) becslő: Speciális ML becslő: a megfigyelési zaj **Gauss** eloszlású, a megfigyelési egyenlet **lineáris**.

N megfigyelést végzünk, \mathbf{n} az N dimenziós zaj-vektor: $E\{\mathbf{n}\} = 0$, $cov\{\mathbf{n}, \mathbf{n}\} = \Sigma_{nn}$

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

A megfigyelési egyenlet: $\mathbf{z} = \mathbf{U}\mathbf{a} + \mathbf{n}$, amellyel a csatorna karakterisztika:

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

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

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

$$\mathbf{U}^T \Sigma_{nn}^{-1} (\mathbf{z} - \mathbf{U}\mathbf{a}) \Big|_{\mathbf{a}=\hat{\mathbf{a}}_{GM}} = 0 \rightarrow \hat{\mathbf{a}}_{GM} = [\mathbf{U}^T \Sigma_{nn}^{-1} \mathbf{U}]^{-1} \mathbf{U}^T \Sigma_{nn}^{-1} \mathbf{z} \text{ ha } [\mathbf{U}^T \Sigma_{nn}^{-1} \mathbf{U}]^{-1} \text{ létezik.}$$

Várható értéke: Σ_{nn}

A becslés minőségjellemzője:

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

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

Megjegyzések:

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

Ha $\Sigma_{aa}^{-1} = 0$, vagyis a szórás végtelen, akkor

$$\hat{\mathbf{a}}_{MS} = \hat{\mathbf{a}}_{GM}$$

A Gauss-Markov becslő torzítatlan: $E\{\hat{\mathbf{a}}_{GM}\} = \mathbf{a}$

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

A csatorna karakterisztika:

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

$$\frac{\partial \ln f(\mathbf{z}|\mathbf{a})}{\partial a} \Big|_{\hat{\mathbf{a}}=\hat{\mathbf{a}}_{ML}=\hat{\mathbf{a}}_{GM}} = \frac{N}{\sigma_n^2} \left[\frac{1}{N} \sum_{k=0}^{N-1} z_k - a \right] = 0,$$

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

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