



# Beágyazott információs rendszer

5. Mennyiségek, változók  
valós idejű rendszerekben


2020. október 22.

## 5. Mennyiségek, változók valós idejű rendszerekben

**Előzmények:** Real-time változó, real-time változó képe, időbeni pontosság, periodikus frissítés, megfigyelés: állapotmegfigyelés, eseménymegfigyelés, valós idejű objektum, állandóság, akciókésleltetés, idempotencia, hihetőség (bizánci típusú hibák), befolyásolhatóság, ...

**A befogadó környezet modellezése:**

**Ami nem megkerülhető:** A befogadó környezet **megismerése**, majd a működtető **szoftverbe építése!** Ennek eszköze a **mérési eljárás**: a megismerési folyamat része, amelynek során a rendelkezésünkre álló ismereteinket pontosítjuk, ill. bővítjük.



Az ábra a folyamat interpretálását segíti. A mérés során a **valóság** jelenségeit szeretnénk **megragadni**.


Ezt a „megragadást” előszeretettel végezzük olyan jellemzőkre építve, amelyek valamilyen értelemben **stabilitást** mutatnak.

Ilyen jellemzőkhöz (is) **absztrakció** révén jutunk.

A valóság „tere” egy olyan absztrakció, amelyben a vizsgált jellemzők konkrét értékei a tér egy pontjának felelnek meg.

- az állapotváltozók ( $x$ ), amelyek változásai a kölcsönhatások révén fellépő energiafolyamatokhoz köthetők (feszültség, nyomás, hőmérséklet, sebesség, stb.)
- a paraméterek ( $a$ ), amelyek a kölcsönhatások intenzitásviszonyait ragadják meg, és
- a struktúrák ( $S$ ), amelyek a rendszerkomponensek kapcsolatait írják le.






A mérés előtt a pont koordinátáit **nem ismerjük**.

A mérések során egy-egy ilyen pont koordinátáinak meghatározására (megmérésére) törekszünk, ami – ismert módon – **csak közelítőleg** lehetséges (a mérés hibával terhelt).

További nehézség, hogy a **mérendő mennyiséghez** sok esetben nem férünk közvetlenül hozzá, ezért többnyire csak valamilyen leképezésből tudunk kiindulni.

Ezt a leképezést nevezük **megfigyelésnek**.

A mérendő és a megfigyelt érték közötti út a **mérési/jelátviteli csatorna**.



**Megfigyelés determinisztikus csatorna esetén:**

A megfigyelt “valóságot” autonóm rendszerként képzeljük el, és diszkrét modellel írjuk le. A „valóságot” és a megfigyelést leíró állapot, ill. megfigyelési egyenletek:

$$x(n+1) = Ax(n), \quad \dim[x(n)] = N, \quad \dim[A] = N * N$$


$$y(n) = Cx(n) \quad \dim[y(n)] = M, \quad M \leq N, \quad \dim[C] = M * N$$

Tudunk egy ilyen modellt invertálni? **Általában nem!** Mikor tudunk? **Ha  $C^{-1}$  létezik!**



Ha **nem létezik**  $C^{-1}$ , akkor mást kell csinálni! A megoldás egy **szimulátor!**

Ehhez a modellnek **be kell épülnie** a számítógépbe! Ezt vezéreljük a **megfigyelt értékekkel!**



Ennek az eszköznek a neve: **megfigyelő**, amely a „valóság” **másolata** igyekszik lenni azért, hogy egy korrekciós/tanuló/adaptáló mechanizmus eredményeképpen **követi** azt.

A követés bekövetkeztével a mérés „eredménye”  $\hat{x}(n)$  a megfigyelőből olvasható ki.

A megfigyelőben megvalósuló „**másolat**” állapot, ill. megfigyelési egyenletei:

$$\hat{x}(n+1) = A\hat{x}(n) + Ge(n)$$

$G$ : **korrekciós mátrix**;  $\dim[G] = N * M$ ,  $e(n) = y(n) - \hat{y}(n)$   
A  $G$  mátrixot úgy tervezzük meg, hogy  $\hat{x}(n) \rightarrow x(n)$ .

$$\hat{y}(n) = C\hat{x}(n)$$

A minimalizálandó állapothiba az állapotegyenletek különbségként:

$$x(n+1) - \hat{x}(n+1) = Ax(n) - A\hat{x}(n) - Ge(n) = \underbrace{(A - GC)}_F \underbrace{(x(n) - \hat{x}(n))}_{\varepsilon(n)}$$

$$\varepsilon(n+1)$$

$$\varepsilon(n+1) = F\varepsilon(n)$$


$$F$$

$$\varepsilon(n)$$

az ún. hibarendszer állapotátmenet mátrixa.

A  $G$  mátrix tervezése:  $\varepsilon(n) \xrightarrow[n \rightarrow \infty]{} 0$ , aminek érdekében  $\varepsilon(n+1) < \varepsilon(n)$ , lehetőleg  $\forall n$ -re.

$F$  csökkenti  $\varepsilon(n)$  hosszát minden lépésben: „**kontraktív**”. Az  $\varepsilon(n)$  hibavektorral kapcsolatos egyenlőtlenség a vektor hosszára (normájára) értelmezendő, skálár esetben pedig a hiba abszolút értékére. **Elvárás**: a hibarendszer a belső energiáját **disszipálja**.



**Esetek:**

1.  $F = A - GC = 0$ . Ebben az esetben  $G = AC^{-1}$ . Ez akkor lehetséges, ha  $C$  négyzetes, azaz a megfigyelés éppen annyi komponensű, mint maga az állapotvektor.

Az egyenlet explicit formában megoldható! A konvergencia egyetlen lépéses!

2.  $F^N = (A - GC)^N = 0$ . Ebben az esetben a hibarendszer  $N$  lépésben konvergál:

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

Az  $F^N = 0$  tulajdonságú mátrixok, az

ún. **nemderogatórius nilpotens** mátrixok, amelyek sajátja, hogy **valamennyi sajátértékük nulla**.

Az ilyen tulajdonságú állapotátmenet mátrixszal jellemezhető rendszerek **véges impulzusválaszúak** (ún. **FIR** rendszerek), hiszen a kezdeti hiba **véges lépésben** eltűnik.

3. Ha  $F^N = (A - GC)^N \neq 0$ , akkor a stabilra tervezett hibarendszer állapotvektorának hossza **exponenciális jelleggel** fog csökkenni. Egy ilyen hibarendszer akkor lesz **stabil**, ha összes **sajátértéke** az egységsugarú körön **belül** helyezkedik el. Az ilyen tulajdonságú állapotátmenet mátrixszal jellemezhető rendszerek **végtelen impulzusválaszúak** (ún. **IIR** rendszerek), mert a kezdeti hiba csak **végtelen lépésben** tűnik el.

**Megfigyelés zajos csatorna esetén:** Ebben az esetben nem  $\varepsilon(n) \xrightarrow{n \rightarrow \infty} 0$  az elvárásunk, hanem az, hogy  $\text{trace}\{E[\varepsilon(n)\varepsilon^T(n)]\} \xrightarrow{n \rightarrow \infty} \min$  legyen.

$$\varepsilon(n) = \begin{bmatrix} \varepsilon_0(n) \\ \varepsilon_1(n) \\ \vdots \\ \varepsilon_{N-1}(n) \end{bmatrix} \quad \text{ezért} \quad \text{trace}\{E[\varepsilon(n)\varepsilon^T(n)]\} = \sum_{k=0}^{N-1} \varepsilon_k^2(n).$$

$$\varepsilon(n+1) = F\varepsilon(n)$$

helyett

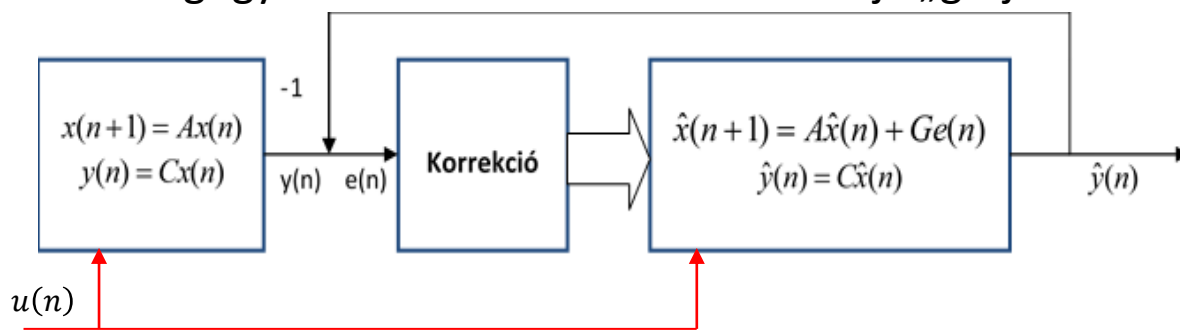
$$E[\varepsilon(n+1)\varepsilon^T(n+1)] = FE[\varepsilon(n)\varepsilon^T(n)]F^T$$

hibarendszer jellemzést használunk.



Ez a  $P = E[\varepsilon(n)\varepsilon^T(n)]$  hiba-mátrix központi szerepet kap a híres Kalman prediktor, ill. szűrő esetében. **Megjegyzések:**

1. A megfigyelő elrendezés mindkét modellje „gerjeszthető” egy közös gerjesztéssel.




Mivel a modellek lineárisak, a **szuperpozíció** értelmében a megfigyelő konvergenciája változatlanul megvalósul.

2. Az ábra szerinti megfigyelőt **Luenberger megfigyelő**nek nevezzük. Luenberger szerint **majdnem minden rendszer** megfigyelő. A megfigyelő tulajdonság feltétele, hogy a megfigyelő legyen „gyorsabb”, mint a megfigyelt rendszer, különben nem képes követni a változásokat.

3. Egy ellenállás- vagy impedancia-mérő híd ismeretlen elemet tartalmazó hídága a valóság **fizikai modellje**, a kiegyenlítő elemet tartalmazó ága pedig a megfigyelőben felépülő, **beállítható/hangolható modell**.

A hídágak osztópontján megjelenő feszültségek különbsége vezérli a hangolást, és a végén a két feszültség megegyezik, a beállítható elemről leolvasott érték segítségével meghatározható az ismeretlen. Ez az áramkör, a hangolást végző operátor részvételével megvalósítja a megfigyelőt.



**Példa:**

$$\text{Adott } A = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}; C = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

Hogyan állítsuk be  $G$ -t?

$$G = AC^{-1} = A = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$$



**Példa:** Adott  $A = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}; C = [1 \quad 1]$ . Hogyan állítsuk be  $G$ -t?  $G = \begin{bmatrix} g_0 \\ g_1 \end{bmatrix} = ?$

$$GC = \begin{bmatrix} g_0 \\ g_1 \end{bmatrix} [1 \quad 1] = \begin{bmatrix} g_0 & g_0 \\ g_1 & g_1 \end{bmatrix}, \quad [A - GC] = \begin{bmatrix} 1 - g_0 & -g_0 \\ -g_1 & -1 - g_1 \end{bmatrix}, \quad [A - GC]^2 = 0 \text{ alapján.}$$

$$\begin{bmatrix} 1 - g_0 & -g_0 \\ -g_1 & -1 - g_1 \end{bmatrix} \begin{bmatrix} 1 - g_0 & -g_0 \\ -g_1 & -1 - g_1 \end{bmatrix} = \begin{bmatrix} 1 - 2g_0 + g_0^2 + g_0g_1 & -g_0 + g_0^2 + g_0 + g_0g_1 \\ -g_1 + g_1^2 + g_1 + g_0g_1 & 1 + 2g_1 + g_1^2 + g_0g_1 \end{bmatrix} =$$

$$= \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix} \text{ A mellékátló kifejezéseit a főátló kifejezéseibe behelyettesítve kapjuk:}$$

$$\boxed{1 - 2g_0 = 0}, \quad \boxed{1 + 2g_1 = 0}, \quad \text{amiből: } g_0 = 0.5 \text{ és } g_1 = -0.5.$$

Ellenőrzésképpen:  $\begin{bmatrix} 0.5 & -0.5 \\ 0.5 & -0.5 \end{bmatrix} \begin{bmatrix} 0.5 & -0.5 \\ 0.5 & -0.5 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix}$

**Példa:** Határozzuk meg  $[A - GC]$  sajátértékeit erre az esetre:  $\det[\lambda I - A + GC] = 0$

$$\det \begin{bmatrix} \lambda - 0.5 & 0.5 \\ -0.5 & \lambda + 0.5 \end{bmatrix} = (\lambda - 0.5)(\lambda + 0.5) + 0.25 = \lambda^2 - 0.25 + 0.25 = 0.$$

Mindkét sajátérték nulla.

### Megjegyzések:

1. Ez a tulajdonság **általánosan igaz** véges lépésben konvergálni képes rendszerek esetében.
2. Az ilyen rendszerek átviteli függvénye olyan (elfajuló) racionális törtfüggvény, amelynek **valamennyi pólusa az origóban** van:

$$H(z) = a_1 z^{-1} + a_2 z^{-2} + \dots + a_N z^{-N} = \frac{a_N + a_{N-1}z + a_{N-2}z^2 + \dots + a_1 z^{N-1}}{z^N}$$

Ezek az ún. **véges impulzusválaszú (FIR)** szűrők.

Időtartománybeli megfelelője:  $y(n) = a_1 x(n-1) + a_2 x(n-2) + \dots + a_N x(n-N)$ ,

ahol a valós idejű **kiszámíthatóság** miatt csak  $x(n)$  korábbi mintái szerepelhetnek.



**Példa:** A sajátértékekre vonatkozó feltétel felhasználható a  $g_0$  és a  $g_1$  értékek meghatározására:

$$\det[\lambda I - A + GC] = 0, \quad \det \begin{bmatrix} \lambda - 1 + g_0 & g_0 \\ g_1 & \lambda + 1 + g_1 \end{bmatrix} = \lambda^2 + \lambda(g_0 + g_1) + g_0 - g_1 - 1 = \\ = \lambda^2 = 0. \text{ Ebből: } g_0 + g_1 = 0, \text{ ill. } g_0 - g_1 = 1, \text{ amiből: } g_0 = 0.5 \text{ és } g_1 = -0.5.$$

Van, hogy a befogadó környezet „dinamikáját” közvetlenül nem ismerjük:  
Az állapotegyenlet nem ismert vagy  $A = I$ . Ekkor csak megfigyeléseink vannak.

**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:  $y(n) = Cx(n) + w(n)$ ;  $w(n)$  megfigyelési zaj

Feltételezzük, hogy az  $x(n)$  ismeretlen  $\hat{x}(n)$  értéket vesz fel, és felállítjuk a **megfigyelés**

**modelljét:**  $C\hat{x}(n)$ . A megfigyelést ezzel összevetve keressük  $\hat{x}(n)$  legjobb beállítását négyzetes

hibafüggvény feltételezésével:  $J(x(n), \hat{x}(n)) = (y(n) - C\hat{x}(n))^T (y(n) - C\hat{x}(n)) =$

$$= y(n)^T y(n) - y(n)^T C\hat{x}(n) - \hat{x}(n)^T C^T y(n) + \hat{x}(n)^T C^T C\hat{x}(n) =$$

$= y(n)^T y(n) - 2\hat{x}(n)^T C^T y(n) + \hat{x}(n)^T C^T C\hat{x}(n)$  melynek szélsőértékét (minimumát) keressük:

$$\left. \frac{\partial J(x(n), \hat{x}(n))}{\partial \hat{x}(n)} \right|_{\hat{x}(n)=\hat{x}_{LS}} = 0 \quad -2C^T y(n) + 2C^T C\hat{x}(n) = 0, \quad \hat{x}(n) = [C^T C]^{-1} C^T y(n)$$

Itt  $A = I$  miatt  $x(n)$  valójában konstans, tipikusan paraméter.

Többször is megfigyeljük, és a megfigyelt (zajos) értékeket  $y(n)$  vektorba gyűjtjük.

Ha  $C = [1 \ 1 \ \dots \ 1]^T$ , akkor

$$\hat{x}_{LS} = \frac{1}{N} \sum_{k=0}^{N-1} y_k(n)$$

Azaz az egyszerű átlagolásra jutunk.






# Modellillesztés

A legkisebb négyzetes hibájú becslők esetén nincs előzetes ismeretünk, valójában modellt illesztünk.

A modellillesztés problémája meglehetősen szerteágazó.

Egyik klasszikus válfaja a **regresszió számítás**: függő és független változók közötti közvetlen, determinisztikus kapcsolat meghatározása, a modellillesztés egy speciális esete.



Az ábrán látható elrendezésben a modellezendő  $y = g(u, n)$  függvény **kétfajta független változóval** rendelkezik: az egyiket  $u(n)$  jelöli, **amelyet ismerünk** és „kézben tudunk tartani”, a másik, amelyet  $n(n)$  jelöli, **amely ismeretlen**, kézben nem tartható, tipikusan zajfolyamatnak elképzelt/modellezett folyamat.

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:

$$J = E\{(y - \hat{y})^T (y - \hat{y})\}$$

**Lineáris regresszió:** Az illesztendő függvény a  $\hat{g}(u) = a_0 + a_1 u$  skálár lineáris függvény, melynek paraméterei úgy választandók meg, hogy  $E\{(y - \hat{g}(u))^2\}$  minimális legyen.

Minimalizálandó a  $J = E\{(y - a_0 - a_1 u)^2\}$  összefüggés  $a_0$  és  $a_1$  szerint:

$$\frac{\partial J}{\partial a_0} = -2E\{(y - a_0 - a_1 u)\} = -2(E\{y\} - a_0 - a_1 E\{u\}) = 0$$

$$\frac{\partial J}{\partial a_1} = -2E\{u(y - a_0 - a_1 u)\} = -2(E\{uy\} - a_0 E\{u\} - a_1 E\{u^2\}) = 0$$



**Polinomiális regresszió:** Fontos tulajdonsága, hogy paramétereiben lineáris.

$\hat{g}(u) = \sum_{k=0}^N a_k u^k$  A paramétereiben lineáris modellek előnyösek, mert négyzetes hibakritérium esetén a szélsőérték-keresés lineáris egyenletrendszer megoldására vezet: négyzetes kifejezések paraméterek szerinti deriválása lineáris összefüggést eredményez.

### Lineáris regresszió mérési adatok alapján:

A fentieket végigvihetjük akkor is, ha nincsen előzetes információnk.

Ilyenkor  $y_n = a_0 + a_1 u_n + w_n$ , ami az  $n$ -edik időpillanatban végzett megfigyelés modellje.

Végzünk  $N$  megfigyelést. A „bemenet” és a megfigyelt értékeket vektorba rendezzük.

$$\mathbf{z} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_{N-1} \end{bmatrix} = \begin{bmatrix} 1 & u_0 \\ 1 & u_1 \\ \vdots & \vdots \\ 1 & u_{N-1} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} + \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{N-1} \end{bmatrix}$$

Felismerjük, hogy ez a struktúra ugyanaz, mint a **legkisebb négyzetes hibájú becslő**knél megismert!

$$y(n) = C * x(n) + w(n)$$


$$[C^T C] = \begin{bmatrix} N & \sum_{n=0}^{N-1} u_n \\ \sum_{n=0}^{N-1} u_n & \sum_{n=0}^{N-1} u_n^2 \end{bmatrix},$$

$$C^T \mathbf{z} = \begin{bmatrix} \sum_{n=0}^{N-1} y_n \\ \sum_{n=0}^{N-1} u_n y_n \end{bmatrix},$$

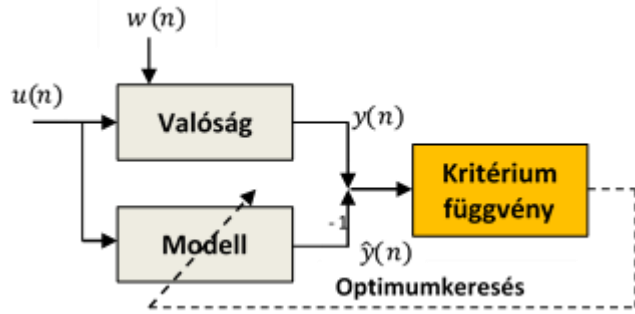
$$\hat{x}(n) = [C^T C]^{-1} C^T y(n)$$

$$\begin{bmatrix} \hat{a}_0 \\ \hat{a}_1 \end{bmatrix} = \frac{1}{\frac{1}{N} \sum_{n=0}^{N-1} u_n^2 - \left(\frac{1}{N} \sum_{n=0}^{N-1} u_n\right)^2} \begin{bmatrix} \frac{1}{N} \sum_{n=0}^{N-1} u_n^2 & -\frac{1}{N} \sum_{n=0}^{N-1} u_n \\ -\frac{1}{N} \sum_{n=0}^{N-1} u_n & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{N} \sum_{n=0}^{N-1} y_n \\ \frac{1}{N} \sum_{n=0}^{N-1} u_n y_n \end{bmatrix},$$


Felismerjük a statisztikai jellemzők közelítő összefüggéseit!




## A regressziós séma általánosítása




A modell-illesztési feladat megfigyelőként ábrázolva



Inverz modell illesztése



## Adaptív lineáris kombinátor



Az általánosított regressziós sémához kapcsolódó egyik gyakran használt modell-család. Ebben az  $u(n)$  diszkrét értéksorozatból egy  $\mathbf{X}^T(n) = [x_0(n) \ x_1(n) \ \dots \ x_{N-1}(n)]$  értéksorozatot állítunk elő először, majd ezen értékek lineáris kombinációjaként állítjuk elő az  $\hat{y}(n)$  értéket. A  $\mathbf{W}^T(n) = [w_0(n) \ w_1(n) \ \dots \ w_{N-1}(n)]$  paraméterek legkedvezőbb, minimális négyzetes hibát eredményező beállítására törekszünk.

$$J(\mathbf{W}(n)) = E\{[y(n) - \mathbf{X}^T(n)\mathbf{W}(n)]^T [y(n) - \mathbf{X}^T(n)\mathbf{W}(n)]\} =$$

$$= E\{y^T(n)y(n)\} - 2\mathbf{W}^T(n)E\{\mathbf{X}(n)y(n)\} + \mathbf{W}^T(n)E\{\mathbf{X}(n)\mathbf{X}^T(n)\}\mathbf{W}(n).$$

$$E\{\mathbf{X}(n)y(n)\} = \mathbf{P}$$

$$\frac{\partial J(\mathbf{W}(n))}{\partial \mathbf{W}(n)} = -2\mathbf{P} + 2\mathbf{R}\mathbf{W}(n) = 0$$

$$\mathbf{W}^* = \mathbf{R}^{-1}\mathbf{P}$$

$$E\{\mathbf{X}(n)\mathbf{X}^T(n)\} = \mathbf{R}$$

Wiener-Hopf egyenlet.

