



Beágyazott információs rendszerek

5. Mennyiségek, változók
valós idejű rendszerekben

2020. október 28.

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.

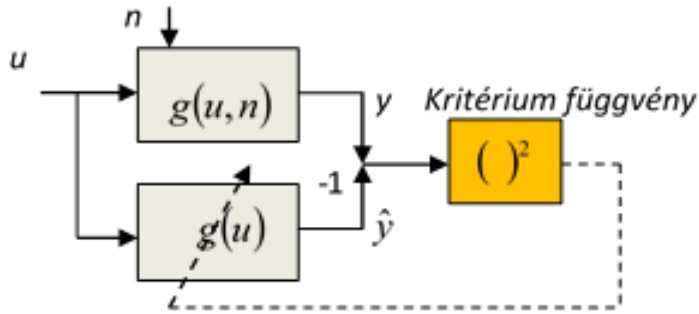


Modellillesztés

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 $\hat{g}(u) = a_0 + a_1 u$ skalár 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!

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


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

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

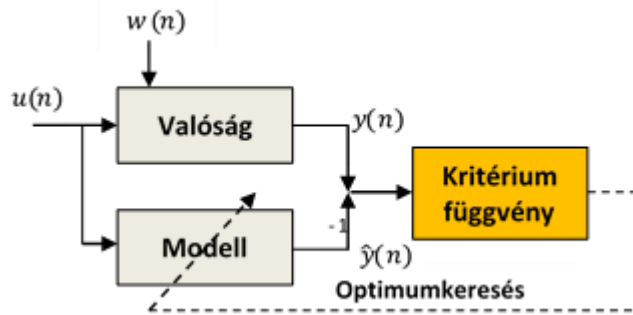
$$\hat{x}(n) = [C^T C]^{-1} C^T y(n)$$

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


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.



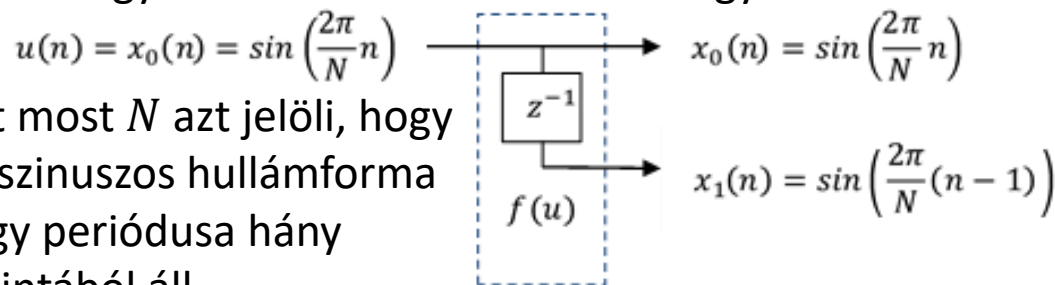
Az optimális beállítás minimális hibát eredményez, amit visszahelyettesítéssel kapunk:
 $J_{min} = E\{y^T(n)y(n)\} - \mathbf{P}^T \mathbf{R}^{-1} \mathbf{P} = E\{y^T(n)y(n)\} - \mathbf{P}^T \mathbf{W}^*$ Ennek felhasználásával:

$$J(\mathbf{W}(n)) = J_{min} + (\mathbf{W}(n) - \mathbf{W}^*)^T \mathbf{R} (\mathbf{W}(n) - \mathbf{W}^*) = J_{min} + \mathbf{V}^T(n) \mathbf{R} \mathbf{V}(n)$$

ahol $\mathbf{V}(n) = \mathbf{W}(n) - \mathbf{W}^*$ az ún. paraméterhiba vektora. **Példa:**



Legyen $\mathbf{X}^T(n) = [\sin(2\pi n/N) \quad \sin(2\pi(n-1)/N)]$, azaz egy szinuszos hullámforma két egymás utáni mintája.



Itt most N azt jelöli, hogy a szinuszos hullámforma egy periódusa hány mintából áll.

A jel, amihez az illesztést végezzük: $y(n) = 2 \cos(2\pi n/N)$. $\mathbf{W}^T(n) = [w_0(n) \quad w_1(n)]$

Az \mathbf{R} és a \mathbf{P} mátrixok a szinuszos, ill. koszinuszos hullámformák teljes ($N > 2$) periódusra történő átlagolásával származtathatók:

$$E\{x_0^2(n)\} = E\{x_1^2(n)\} = E\{\sin^2(2\pi n/N)\} = E\{\sin^2(2\pi(n-1)/N)\} = 0.5,$$


$$E\{x_0(n)x_1(n)\} = E\{\sin(2\pi n/N) \sin(2\pi(n-1)/N)\} = 0.5 \cos(2\pi/N)$$

$$E\{x_0(n)y(n)\} = E\{2 \sin(2\pi n/N) \cos(2\pi n/N)\} = 0,$$

$$E\{x_1(n)y(n)\} = E\{2 \sin(2\pi(n-1)/N) \cos(2\pi n/N)\} = -\sin(2\pi/N).$$

$$\mathbf{R} = \begin{bmatrix} 0.5 & 0.5 \cos\left(\frac{2\pi}{N}\right) \\ 0.5 \cos\left(\frac{2\pi}{N}\right) & 0.5 \end{bmatrix}$$

$$\mathbf{P} = \begin{bmatrix} 0 \\ -\sin\left(\frac{2\pi}{N}\right) \end{bmatrix}.$$



Képezve \mathbf{R} inverzét:

$$\mathbf{R}^{-1} = \frac{1}{0.25 \sin^2 \left(\frac{2\pi}{N} \right)} \begin{bmatrix} 0.5 & -0.5 \cos \left(\frac{2\pi}{N} \right) \\ -0.5 \cos \left(\frac{2\pi}{N} \right) & 0.5 \end{bmatrix}$$

$$\mathbf{R} = \begin{bmatrix} 0.5 & 0.5 \cos \left(\frac{2\pi}{N} \right) \\ 0.5 \cos \left(\frac{2\pi}{N} \right) & 0.5 \end{bmatrix}$$

$$\mathbf{W}^* = \mathbf{R}^{-1} \mathbf{P} = \begin{bmatrix} \frac{2}{\tan(2\pi/N)} \\ \frac{2}{\sin(2\pi/N)} \end{bmatrix}$$

Ezzel a paraméter-beállítással az illesztett modell kimenete:


$$\mathbf{P} = \begin{bmatrix} 0 \\ -\sin \left(\frac{2\pi}{N} \right) \end{bmatrix}$$

$$\hat{y}(n) = X^T(n) \mathbf{W}^* = 2 \frac{\sin(2\pi n/N)}{\tan(2\pi/N)} - 2 \frac{\sin(2\pi(n-1)/N)}{\sin(2\pi/N)} = 2 \cos(2\pi n/N)$$

Mivel szinuszos minták lineáris kombinációjával hiba nélkül elő lehet állítani koszinuszos hullámformák mintáit, ezért a példa szerinti esetben J_{min} , azaz a hibafelület parabolooid legalsó pontja érinti a paraméterek síkját.

Út az adaptív eljárásokhoz


A hibafelület tetszőleges pontjában a hiba csökkenés fajlagos mértékét a felület meredekségével (gradiensével) mérhetjük:



$$\nabla(n) = \frac{\partial J(\mathbf{W}(n))}{\partial \mathbf{W}(n)} = 2\mathbf{R}[\mathbf{W}(n) - \mathbf{W}^*]$$

Ez utóbbi mindkét oldalát megszorozva balról az $\frac{1}{2} \mathbf{R}^{-1}$ mátrixszal:

$$\mathbf{W}^* = \mathbf{W}(n) - \frac{1}{2} \mathbf{R}^{-1} \nabla(n), \text{ ahol felhasználtuk: } \mathbf{W}^* = \mathbf{R}^{-1} \mathbf{P}$$



Feltételezve, hogy nincs tökéletes ismeretünk az \mathbf{R} mátrixról, és ebből adódóan a gradienstől, ez átírható egy iteratív formára:

$$\mathbf{W}^* = \mathbf{W}(n) - \frac{1}{2}\mathbf{R}^{-1}\nabla(n) \quad \Longrightarrow \quad \mathbf{W}(n+1) = \mathbf{W}(n) - \frac{1}{2}\hat{\mathbf{R}}^{-1}\hat{\nabla}(n),$$

illetve a konvergencia sebességét meghatározó $0 < \mu < 1$ „bátorsági” tényező bevezetésével, visszaírva a „tökéletes” \mathbf{R} mátrixot és gradienst:

$$\mathbf{W}(n+1) = \mathbf{W}(n) - \mu\mathbf{R}^{-1}\nabla(n) \quad (*)$$

Megjegyzések:

1. Ha pontosan ismerjük az \mathbf{R} mátrixot és gradienst, akkor $\mu = \frac{1}{2}$ egy lépéses konvergenciát biztosít tetszőleges $\mathbf{W}(n)$ kezdőpontból.
2. Mivel $\nabla(n) = 2\mathbf{R}[\mathbf{W}(n) - \mathbf{W}^*]$, ezért ezt a (*) összefüggésbe behelyettesítve, és az egyenlet mindkét oldalából levonva \mathbf{W}^* értékét:

$$\mathbf{W}(n+1) - \mathbf{W}^* = (1 - 2\mu)(\mathbf{W}(n) - \mathbf{W}^*) = \mathbf{V}(n+1) = (1 - 2\mu)^{n+1}\mathbf{V}(0), \quad (**)$$

vagyis a kezdeti hiba exponenciális jelleggel csökken, ha $\mu \neq \frac{1}{2}$.

Ha $0 < \mu < 0.5$, akkor monoton csökkenő hibával, ellenkező esetben pedig monoton csökkenő amplitúdójú, de lengő jellegű hibával közelítjük meg.

3. A modell-illesztés gradiens módszereit a szerint különböztetjük meg, hogy a (*) szerinti összefüggés (közelítő) alkalmazásához milyen előzetes ismeretek állnak rendelkezésünkre. Amennyiben az \mathbf{R} és a \mathbf{P} mátrixok pontosan ismertek, akkor az adaptív lineáris kombinátor működését a (*) és (**) egyenletek írják le.
4. Figyeljük meg, hogy az \mathbf{R} mátrix „globális” információt hordoz a hibafelületről, a $\nabla(n)$ gradiens pedig a hibafelület „lokális” jellemzése. Ezen lokális ismeret alapján „ereszkedünk” a hibafelületen, hogy minél közelebb kerüljünk az optimumhoz.



A replikátum determinizmusa

Ha a megbízhatóságot aktív redundanciával, azaz fizikai többszörözéssel javítjuk, akkor a párhuzamosan működő egységeknél meg kell követelnünk, hogy

- (1) a kívülről látható RAM állapotuk **ugyanaz legyen**, és
- (2) a **kimenetek azonosak** legyenek, maximum d időbeni eltéréssel.

A d értékét a rendszer dinamikai tulajdonságai alapján határozhatjuk meg: kell, hogy maradjon idő a hibás vagy hiányzó adat pótlására a replikátumból.

Példa: Három csatornás repülés-irányító rendszer többségi szavazással.

Mindegyik csatorna önálló szenzorokkal és számítógépekkel rendelkezik, hogy az ún. közös-módusú hibák valószínűségét minimalizáljuk.

A “felszállás kezdete” eseményt követően egy előírt időn belül a vezérlő rendszernek ellenőriznie kell, hogy a repülőgép **elérte-e a felszálláshoz szükséges sebességet**.

Ha igen, akkor kezdeményezi az emelkedést és **a motorokat tovább gyorsítja**.

Ha nem, akkor a felszállási folyamat megszakítandó, és **a motorokat le kell állítani**.

Az alábbi táblázat egy olyan helyzetet ír le, ahol a replikátum determinizmusa feltétel nem teljesül, és a hibás csatorna érvényesül a döntésben:

Csatorna	Döntés	Akció
1. csatorna	Felszállás	Motor gyorsítása
2. csatorna	Megszakítás	Motor leállítása
3. csatorna	Megszakítás	Motor gyorsítása

A táblázat szerinti első két csatorna helyesen működik, csak nem teljesül a replikátum determinizmusa feltétel.

Véletlen hatások eredményeképpen (eltérés a

szenzor kalibrációban, digitalizálási hiba, a sebességmérés időpontjában kicsi eltérés) a két csatorna eltérő következtetésre jut. A harmadik csatorna hibásan működik, mert megszakítást dönt, és gyorsítja a motort.



Az akcióra vonatkozó **többségi szavazás a hibás csatorna által javasolt eredményt hoz** a replikátum determinizmusára vonatkozó feltétel teljesülésének hiányában!


Mintavételezés és lekérdezés:

Mintavételezés (sampling) szóhasználatlal élünk, ha az adatot a szenzor egységnél írjuk memóriába:



A memória a számítógép befolyásolhatósági tartományán kívül helyezkedik el. A számítógép leállása, újraindulása esetén a memóriatartalom nem vész el.

Lekérdezés (polling) szóhasználatlal élünk, ha az adatot a számítógép memóriájába helyezzük:



Funkcionális szempontból a két megoldás nem tér el egymástól, de hiba esetén **a mintavételezés robusztusabb**.

Megjegyzés: Az **interrupt** mechanizmus a **polling**-ot bemutató ábrával jellemezhető.

Súlyos problémája, hogy külső eszköz befolyásolhatósági tartományába helyezi a számítógépet, ezért fokozott körültekintéssel kell alkalmazni, mert hiba esetén oly mértékben túlterhelheti a processzort, hogy az képtelen lesz feladatait (időre) ellátni.

