

*Dinamikus rendszerek paramétereinek becslése*  
*Rekurzív paraméterbecslés, felejtés*

**Hangos Katalin, Szederkényi Gábor**

PE Villamosmérnöki és Információs Rendszerek Tanszék

# *ISMÉTLÉS*

# LKN becslés paraméterekben lineáris esetben

---

A predikciós hiba:

$$\varepsilon(k, \theta) = y(k) - \theta^T \varphi(k)$$

A minimalizálandó kritériumfüggvény:

$$V_N(\theta, D^N) = \frac{1}{N} \sum_{k=1}^N \frac{1}{2} [y(k) - \theta^T \varphi(k)]^2$$

aminek minimális értéke  $\theta$  függvényében adja az LKN-becslést:

$$\hat{\theta}_{LS} = \left[ \frac{1}{N} \sum_{k=1}^N \varphi(k) \varphi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N \varphi(k) y(k)$$

# *A REKURZÍV PARAMÉTERBECSLŐ ELJÁRÁSOK*

## A rekurzív paraméterbecslő algoritmusok általános alakja

---

$$\hat{\theta}(\mathbf{k}) = \mathbf{F}(\hat{\theta}(\mathbf{k} - 1), \mathbf{S}(\mathbf{k}), \mathbf{Z}(\mathbf{k}))$$
$$\mathbf{S}(\mathbf{k}) = \mathbf{H}(\mathbf{S}(\mathbf{k} - 1), \hat{\theta}(\mathbf{k} - 1), \mathbf{Z}(\mathbf{k}))$$

- $\hat{\theta}(k)$  a becsült **paramétervektor** értéke a  $k$ -adik időpillanatban;
- $Z(k)$  a rendelkezésre álló **mérési adatok** értéke a  $k$ -adik időpillanatban;
- $S(k)$  a **segédváltozó**;
- $F$  és  $H$  **valamilyen elv szerint megválasztott** vektor bemenetű és vektor értékű **függvények**.

**A rekurzív paraméterbecslés alapproblémája az  $F$  és  $H$  függvények megválasztása.**

Látható, hogy a **becsült paramétervektor értékének frissítéséhez csak az előző időpillanatban rendelkezésre álló becsült paramétervektor- és segédváltozó értékek valamint az aktuális mért adatok szükségesek.**

**Rekurzív becslésekkel kezelhetőek az időben lassan változó, de nem szigorúan időinvariáns rendszerek paraméterbecslésének esetei is.**

# Rekurzív paraméterbecslés

---

## Előnyök:

- **Az adatok feldolgozása "on-line" módon történik, nincs szükség nagy mennyiségű adat tárolására.**
- **Az algoritmus működése közben is eldönthető, hogy mikor érte el a becslés a kívánt pontosságot.**
- **A rekurzív algoritmusok a modell-struktúra finomítását is kisebb számítás- és időigénnyel végzik el, mint nemrekurzív megfelelőik.**

## Hátrányok:

- **Egy adott rekurzív algoritmus futtatásakor még az indítás előtt el kell dönteni, hogy milyen modell-struktúrát használunk, míg "off-line" esetben különböző struktúrákat is kipróbálhatunk.**
- **A rekurzív algoritmusok (kevés kivétellel) nem adnak olyan pontos becslést, mint a nemrekurzív módszerek.** Kellően nagy adatrekordok esetén ez a különbség azonban jelentéktelenné válik.

# A rekurzív legkisebb négyzetek módszere 1

A dinamikus rendszerek széles osztályát diszkrét időben leíró **regressziós modell** a következő:

$$y(k) = \theta^T \varphi(k) + v(k) \quad (1)$$

A paraméterbecslés **súlyozott célfüggvénye**:

$$V_N(\theta) = \frac{1}{N} \sum_{k=1}^N \alpha_k \left[ y(k) - \theta^T \varphi(k) \right] \quad (2)$$

A paramétervektor **legkisebb négyzetes becslését** adó statisztika a  $V_N(\theta)$  minimuma  $\theta$ -ra nézve:

$$\hat{\theta}_{LS}(N) = \left[ \sum_{k=1}^N \alpha_k \varphi(k) \varphi^T(k) \right]^{-1} \sum_{k=1}^N \alpha_k \varphi(k) y(k) \quad (3)$$

Ez rekurzív alakra hozható.

## A rekurzív legkisebb négyzetek módszere 2

Vezessük be a következő jelölést:

$$\bar{R}(t) = \sum_{k=1}^t \alpha_k \varphi(k) \varphi^T(k) \quad (4)$$

$$\bar{R}(t-1) = \bar{R}(t) - \alpha_t \varphi(t) \varphi^T(t) \quad (5)$$

(3)-ből kapjuk, hogy

$$\sum_{k=1}^N \alpha_k \varphi(k) y(k) = \underbrace{\left[ \sum_{k=1}^N \alpha_k \varphi(k) \varphi^T(k) \right]}_{\bar{R}(N)} \hat{\theta}(N) \quad (6)$$

Ha az összegzést  $N$  helyett  $t-1$ -ig végezzük, a következő egyenletet kapjuk:

$$\sum_{k=1}^{t-1} \alpha_k \varphi(k) y(k) = \bar{R}(t-1) \hat{\theta}(t-1) \quad (7)$$



## A rekurzív legkisebb négyzetek módszere 3

A (6) egyenletből kiindulva a fenti összefüggések felhasználásával kapjuk:

$$\begin{aligned}\hat{\theta}(t) &= \bar{R}^{-1}(t) \left[ \sum_{k=1}^t \alpha_k \varphi(k) y(k) \right] = \bar{R}^{-1}(t) \left[ \sum_{k=1}^{t-1} \alpha_k \varphi(k) y(k) + \alpha_t \varphi(t) y(t) \right] \\ &= \bar{R}^{-1}(t) \left[ \bar{R}(t-1) \hat{\theta}(t-1) + \alpha_t \varphi(t) y(t) \right] \\ &= \bar{R}^{-1}(t) \left[ \left( \bar{R}(t) - \alpha_t \varphi(t) \varphi^T(t) \right) \hat{\theta}(t-1) + \alpha_t \varphi(t) y(t) \right] \\ &= \bar{R}^{-1}(t) \left[ \bar{R}(t) \hat{\theta}(t-1) - \alpha_t \varphi(t) \varphi^T(t) \hat{\theta}(t-1) + \alpha_t \varphi(t) y(t) \right] = \\ &= \bar{R}^{-1}(t) \left\{ \bar{R}(t) \hat{\theta}(t-1) + \alpha_t \varphi(t) \left[ -\varphi^T(t) \hat{\theta}(t-1) + y(t) \right] \right\} \\ &= \hat{\theta}(t-1) + \bar{R}^{-1}(t) \varphi(t) \alpha_t \left[ y(t) - \hat{\theta}^T(t-1) \varphi(t) \right]\end{aligned}$$

**A rekurzív legkisebb négyzetek algoritmusának első alakja:**

$$\begin{aligned}\hat{\theta}(t) &= \hat{\theta}(t-1) + \bar{R}^{-1}(t) \varphi(t) \alpha_t \left[ y(t) - \hat{\theta}^T(t-1) \varphi(t) \right] \\ \bar{R}(t) &= \bar{R}(t-1) + \alpha_t \varphi(t) \varphi^T(t)\end{aligned}$$

~~A gyakorlatban nem ezt az alakot használják, mert minden lépésében egy kvadratikus mátrixot ( $\bar{R}$ ) kell invertálni.~~

# Mátrix inverziós lemma

**Lemma:** Legyenek  $A, B, C$  és  $D$  olyan mátrixok, hogy az  $[A + BCD]$  mátrix létezik, kvadratikus és invertálható, valamint  $A$  és  $C$  invertálható. Ekkor igaz a következő egyenlőség

$$[A + BCD]^{-1} = A^{-1} - A^{-1}B [DA^{-1}B + C^{-1}]^{-1} DA^{-1}$$

Ekkor a  $P(t) = \bar{R}^{-1}(t)$  jelöléssel igazak a következő egyenlőségek:

$$P^{-1}(t) = P^{-1}(t-1) + \alpha_t \varphi(t) \varphi^T(t)$$
$$P(t) = \left[ P^{-1}(t-1) + \varphi(t) \alpha_t \varphi^T(t) \right]^{-1}$$

Ha a mátrix inverziós lemmát erre alkalmazzuk, a következő kifejezést kapjuk:

$$P(t) = P(t-1) - P(t-1) \varphi(t) \left[ \varphi^T(t) P(t-1) \varphi(t) + \frac{1}{\alpha_t} \right]^{-1} \varphi^T(t) P(t-1)$$
$$= P(t-1) - \frac{P(t-1) \varphi(t) \varphi^T(t) P(t-1)}{\frac{1}{\alpha_t} + \varphi^T(t) P(t-1) \varphi(t)}$$

## A rekurzív legkisebb négyzetek módszere 4

A rekurzív legkisebb négyzetes becslés algoritmusának gyakorlatban használt formája

$$P(t) = P(t-1) - \frac{P(t-1)\varphi(t)\varphi^T(t)P(t-1)}{\frac{1}{\alpha_t} + \varphi^T(t)P(t-1)\varphi(t)}$$
$$\hat{\theta}(t) = \hat{\theta}(t-1) + \alpha_t P(t)\varphi(t) \left[ y(t) - \hat{\theta}^T(t-1)\varphi(t) \right]$$

### A kezdeti feltételek megválasztása

Az algoritmus indításakor (a  $t_0$  időpillanatban) szükség van  $P$  mátrix és  $\hat{\theta}$  vektor kezdeti értékére, amiből a további értékeket számítjuk. **A kezdeti feltételek megválasztásának szokásos módja** a következő:

$$P(t_0) = \left[ \sum_{k=1}^{t_0} \alpha_k \varphi(k)\varphi^T(k) \right]^{-1} \quad (8)$$

$$\hat{\theta}(t_0) = P(t_0) \sum_{k=1}^{t_0} \alpha_k \varphi(k)y(k) \quad (9)$$

ami egy néhány mintán elvégzett hagyományos (nemrekurzív) legkisebb négyzetes becslés. Így garantálható, hogy a rekurzív algoritmus becsült paraméterének kezdeti értéke nem lesz túlságosan távol a valódi paraméterértéktől.

# *REKURZÍV GRADIENS MÓDSZER*

## A probléma leírása

A legkisebb négyzetes paraméterbecslés kritériumfüggvényének minimalizálásakor nagyban megkönnyítette a helyzetünket, hogy a regressziós modellben a prediktor kimenete lineárisan függ a paramétervektor elemeitől (**paraméterekben lineáris modell**).

A gyakorlatban azonban sokszor adódik olyan modell, amikor ez a lineáris összefüggés nem teljesül. Mi a teendő ilyenkor?

**Ha a kvadratikus kritériumfüggvény**

$(V_N(\theta) = \frac{1}{N} \sum_{k=1}^N [y(k) - \hat{y}(k|\theta)]^2)$  **analitikusan nem minimalizálható, akkor célszerű valamilyen numerikus szélsőérték-kereső eljárást alkalmazni. Azonban a nemrekurzív megoldások nagy számítás- és időigénye gyakran nem teszi lehetővé gyakorlati alkalmazásukat.**

Szerencsére ebben az esetben is **rendelkezésünkre állnak az algoritmusok kedvezőbb számítási tulajdonságokkal rendelkező rekurzív változatai, amelyek közül a gradiens módszert mutatjuk be.**

## Közelítések a rekurzív gradiens módszerhez

---

A **predikciós hiba** definíciója a következő volt:

$$\varepsilon(k, \theta) = y(k) - \hat{y}(k|\theta)$$

Jelöljük  $\psi$ -vel  $\varepsilon$ -nak a  $\theta$  paraméter szerinti negatív parciális deriváltját:

$$\psi(k, \theta) = \left[ -\frac{d}{d\theta} \varepsilon(k, \theta) \right]^T$$

Mivel  $\theta$  valódi értékét nem ismerjük, az eljárásban  $\varepsilon$ -t és  $\psi$ -t a következőképpen **közelítjük**:

$$\hat{\varepsilon}(k, \hat{\theta}) = y(k) - \hat{y}(k|\hat{\theta}(k-1))$$

$$\hat{\psi}(k, \hat{\theta}) = \left[ -\frac{d}{d\hat{\theta}(k-1)} \hat{\varepsilon}(k, \hat{\theta}) \right]^T$$

# A rekurzív gradiens módszer

**A paraméterbecslő algoritmus a következő:**

$$P(k) = P(k-1) - \frac{P(k-1)\hat{\psi}(k, \hat{\theta})\hat{\psi}^T(k, \hat{\theta})P(k-1)}{1 + \hat{\psi}^T(k, \hat{\theta})P(k-1)\hat{\psi}(k, \hat{\theta})}$$
$$\hat{\theta}(k) = \hat{\theta}(k-1) + P(k)\hat{\psi}(k, \hat{\theta})\hat{\varepsilon}(k, \hat{\theta})$$

**Az algoritmus indításához szükséges  $P$  és  $\hat{\theta}$  kezdeti értékének megválasztása, amiktől függ a konvergencia gyorsasága.**

$$\hat{\varepsilon}(k, \hat{\theta}) = y(k) - \hat{y}(k|\hat{\theta}(k-1))$$
$$\hat{\psi}(k, \hat{\theta}) = \left[ -\frac{d}{d\hat{\theta}(k-1)}\hat{\varepsilon}(k, \hat{\theta}) \right]^T$$

# *IDŐBEN VÁLTOZÓ PARAMÉTEREK REKURZÍV BECSLÉSE*



## Problémafelvetés

---

Az eddig tárgyalt valamennyi identifikációs eljárásnál azt feltételeztük, hogy a becsülni kívánt paraméter(vektor) valódi értéke (vagy várható értéke) időben konstans (**idoinvariáns rendszerek**).

**Ha feltesszük, hogy a paramétervektor értéke időben változhat**, akkor ezekkel az eljárásokkal nem tudjuk követni az időbeli változásokat, hiszen mindegyikük egy pontbecslést ad a paraméterek értékeire.

**Olyan algoritmusokra van tehát szükség, amelyek minden diszkrét időpillanathoz rendelnek becsült paraméter értéket (amely követi a változásokat).**

A következőkben e probléma néhány gyakran használt megoldását ismertetjük.

# Időben változó paraméterek követése

---

## Csúszóablakos paraméterbecslés

A csúszóablakos megoldás lényege, hogy a **paramétervektor adott időpillanatbeli értékének becslését csak a legutolsó  $N$  db megfigyelés figyelembevételével végezzük**. Az ennél régebbi méréseket egyszerűen figyelmen kívül hagyjuk. **Az identifikációs algoritmus lehet bármely eddig tárgyalt nemrekurzív vagy rekurzív módszer. Minél nagyobb a csúszóablak mérete** (azaz az egy becsléshez figyelembe vett adatok száma), **annál pontosabb a paraméterbecslés, azonban annál lassabban követhetők paraméterek időbeli változásai**.

## Fokozatos (exponenciális) "felejtés"

Ebben az esetben **a régi mérési adatok az idő előrehaladtával egyre kisebb súlyt kapnak a paraméterbecslésben**, azaz fokozatosan "felejtődnek el". **Két módszert mutatunk be:**

- **Rekurzív legkisebb négyzetek módszere exponenciális felejtéssel**
- **Rekurzív gradiens módszer exponenciális felejtéssel**

## Rekurzív legkisebb négyzetek módszere exponenciális felejtéssel 1

Tekintsük a következő **súlyozott négyzetes kritériumfüggvényt**:

$$V_N(\theta) = \sum_{k=1}^N \bar{\beta}(N, k) [y(k) - \theta^T \varphi(k)]^2$$

ahol rögzített  $N$  esetén  $\bar{\beta}(N, k)$  **monoton nő  $k$  növekedésével**. Ezzel

$$\hat{\theta}(N) = \left[ \sum_{k=1}^N \bar{\beta}(N, k) \varphi(k) \varphi^T(k) \right]^{-1} \left[ \sum_{k=1}^N \bar{\beta}(N, k) \varphi(k) y(k) \right]$$

Legyen  $\bar{\beta}(t, k) = \lambda(t) \bar{\beta}(t-1, k)$ . Ekkor

$$\bar{\beta}(t, k) = \left[ \prod_{j=k+1}^t \lambda(j) \right] \alpha_k, \quad \alpha(k) = \bar{\beta}(k, k), \quad \lambda(k) \leq 1$$

Ha  $\lambda(k) = \lambda$ , akkor

$$\bar{\beta}(t, k) = \lambda^{t-k} \alpha_k$$

ahol  $\lambda$  az ún. **felejtési tényező** (forgetting factor).

## Rekurzív legkisebb négyzetek módszere exponenciális felejtéssel 2

Vezessük be a következő jelölést:

$$\bar{R}(t) = \sum_{k=1}^t \bar{\beta}(t, k) \varphi(k) \varphi^T(k)$$

Ekkor igazak a következő egyenlőségek:

$$\begin{aligned} \bar{R}(t) &= \lambda(t) \bar{R}(t-1) + \alpha(t) \varphi(t) \varphi^T(t) \\ \hat{\theta}(t) &= \bar{R}^{-1}(t) \left[ \sum_{k=1}^{t-1} \bar{\beta}(t, k) \varphi(k) y(k) + \alpha_t \varphi(t) y(t) \right] \\ &= \bar{R}^{-1}(t) \left[ \lambda(t) \sum_{k=1}^{t-1} \bar{\beta}(t-1, k) \varphi(k) y(k) + \alpha_t \varphi(t) y(t) \right] = \\ &= \bar{R}^{-1}(t) \left[ \lambda(t) \bar{R}(t-1) \hat{\theta}(t-1) + \alpha_t \varphi(t) y(t) \right] \\ &= \bar{R}^{-1}(t) \left[ \bar{R}(t) \hat{\theta}(t-1) + \alpha_t \varphi(t) \left[ y(t) - \varphi^T(t) \hat{\theta}(t-1) \right] \right] = \\ &= \hat{\theta}(t-1) + \bar{R}^{-1}(t) \varphi(t) \alpha_t \left[ y(t) - \varphi^T(t) \hat{\theta}(t-1) \right] \end{aligned}$$

## Rekurzív LKN exponenciális felejtéssel

Legyen  $P(t) = \bar{R}^{-1}(t)$ . Ekkor

$$P^{-1}(t) = \lambda(t)P^{-1}(t-1) + \alpha_t \varphi(t) \varphi^T(t)$$

$$P(t) = \left[ \lambda(t)P^{-1}(t-1) + \alpha_t \varphi(t) \varphi^T(t) \right]^{-1}$$

Alkalmazva a mátrix inverziós lemmát a következőt kapjuk:

$$P(t) = \frac{1}{\lambda(t)} P(t-1) - \frac{1}{\lambda(t)} P(t-1) \varphi(t) \left[ \varphi^T(t) \frac{1}{\lambda(t)} P(t-1) \varphi(t) + \frac{1}{\alpha_t} \right]^{-1} \varphi^T(t) P(t-1) \frac{1}{\lambda(t)}$$

**Az exponenciális felejtéssel működő rekurzív legkisebb négyzetes algoritmus tehát a következőképp összegezhető:**

$$P(t) = \frac{1}{\lambda(t)} \left[ P(t-1) - \frac{P(t-1) \varphi(t) \varphi^T(t) P(t-1)}{\frac{\lambda(t)}{\alpha_t} + \varphi^T(t) P(t-1) \varphi(t)} \right]$$
$$\hat{\theta}(t) = \hat{\theta}(t-1) + \alpha_t P(t) \varphi(t) \left[ y(t) - \varphi^T \hat{\theta}(t-1) \right]$$

### Az algoritmus paramétereinek megválasztása

- A **kezdeti feltételek** megválasztására ebben az esetben is igazak a rekurzív legkisebb négyzetes becslésnél leírtak.
- További fontos tervezési paraméter a **felejtési tényező**. Ha  $\lambda$  értéke kicsi, a becslés gyorsan követi a paraméter változásait (gyors a felejtés), de egyben érzékenyebb is lesz a zajra és az esetleges modellezési hibákra. Mindennek az ellenkezője igaz akkor, ha  $\lambda$  értéke nagy (közel van 1-hez).

## Rekurzív gradiens módszer exponenciális felejtéssel

---

Itt csak az **algoritmus végső alakját adjuk meg**, a jelölések azonosak a rekurzív gradiens módszernél használtakkal.

$$P(k) = \frac{P(k-1)}{\lambda(k) + \hat{\psi}^T(k, \hat{\theta})P(k-1)\hat{\psi}(k, \hat{\theta})}$$
$$\hat{\theta}(k) = \hat{\theta}(k-1) + P(k)\hat{\psi}(k, \hat{\theta})\hat{\varepsilon}(k, \hat{\theta})$$

ahol a **felejtési tényező ( $\lambda$ ) szerepe megegyezik a rekurzív felejtő legkisebb négyzetes becslésnél leírtakkal.**