

*Dinamikus rendszerek paramétereinek becslése*  
*A legkisebb négyzetes becslés és tulajdonságai*

**Hangos Katalin**

PE Villamosmérnöki és Információs Rendszerek Tanszék

# *ISMÉTLÉS*

## Kovariancia mártixok - 1

A  $\xi$  valószínűségi változó vektor értékű, azaz

$$\xi : \xi(\omega), \quad \omega \in \Omega, \quad \xi(\omega) \in \mathbb{R}^\mu \quad (1)$$

A változó  $m \in \mathbb{R}^\mu$  várható értéke egy valós vektor.  
Varianciája egy valós elemű négyzetes mártix, az ún. *kovariancia mártix*:

$$COV\{\xi\} = E\{(\xi - E\{\xi\})(\xi - E\{\xi\})^T\}$$

Két skalár értékű valószínűségi változó  $\xi_i$  és  $\xi_j$  kovarianciája:

$$COV\{\xi_i, \xi_j\} = E\{(\xi_i - E\{\xi_i\})(\xi_j - E\{\xi_j\})\}$$

A kovariancia mártixok pozitív definit szimmetrikus mártixok, azaz

$$z^T COV\{\xi\} z \geq 0 \quad , \quad \forall z \in \mathbb{R}^\mu$$

## Kovariancia mártixok - 2

### Lineárisan transzformált valószínűségi változókra

Egy  $\xi(\omega) \in R^n$  vektor értékű valószínűségi változót a  $T \in R^{n \times n}$  nonszinguláris négyzetes transzformációs mátrix alkalmazásával transzformáljuk:

$$\eta = T\xi$$

Az  $\eta$  valószínűségi változó statisztikái:

$$E\{\eta\} = TE\{\xi\} \quad , \quad COV\{\eta\} = TCOV\{\xi\}T^T$$

Lineáris regressziónál

$$\hat{p} = (X^T W X)^{-1} X^T W y$$

$$p \sim \eta, y \sim \xi \text{ és } T = (X^T W X)^{-1} X^T W$$

# *A PREDIKCIÓS HIBA MINIMALIZÁLÁSA*

## Prediktív input-output modellek: SISO eset

$$\hat{y}(k|\theta) = W_y(q^{-1}, \theta)y(k) + W_u(q^{-1}, \theta)u(k)$$

A fenti egyenletbeli  $W_y(q^{-1}, \theta)$  és  $W_u(q^{-1}, \theta)$  tényezok úgynevezett *lineáris szurok*, a  $\theta$  az állandó, ismeretlen, becsülni kívánt paraméterek vektora.

A diszkrét ideju lineáris idoinvariáns egybemenetu-egykimenetu (DT-LTI SISO) sztochasztikus rendszerek általános alakú bemenet-kimenet modellje

$$A^*(q^{-1})y(k) = B^*(q^{-1})u(k) + C^*(q^{-1})e(k)$$

prediktív alakban:

$$\hat{y}(k|\theta) = y(k) - e(k) = (1 - H^{-1}(q^{-1}, \theta))y(k) + (H^{-1}(q^{-1}, \theta)G(q^{-1}, \theta))u(k)$$

ahol

$$H^{-1}(q^{-1}, \theta) = \frac{A^*(q^{-1})}{C^*(q^{-1})}, \quad G(q^{-1}, \theta) = \frac{B^*(q^{-1})}{A^*(q^{-1})}$$

## ARX modellek prediktív alakja

Tekintsük a legegyszerűbb esetet, amikor az általános

$$A^*(q^{-1})y(k) = B^*(q^{-1})u(k) + C^*(q^{-1})e(k)$$

alakú input-output modellben a mozgóátlag tag nulla, azaz a *kimeneti rendszerzaj fehér*.

Ebben az esetben  $C^*(q^{-1}) = 1$ .

Ekkor  $H^{-1}(q^{-1}, \theta) = A^*(q^{-1})$  és így

$$W_y(q^{-1}, \theta) = 1 - A^*(q^{-1}) \quad , \quad W_u(q^{-1}, \theta) = B^*(q^{-1})$$

A becslő elemei:

$$\theta = [-a_1 \quad -a_2 \quad \dots \quad -a_n \quad b_0 \quad b_1 \quad \dots \quad b_m]^T \quad , \quad N > n + m$$

$$\hat{y}(k|\theta) = -a_1 y(k-1) - \dots - a_n y(k-n) + b_0 u(k) + \dots + b_m u(k-m)$$

# Nemlineáris idoinvariáns egykimenetű rendszerek

## Mért érték sorozat

$$D[1, N] = D^N = \{(y(k), u(k)) \mid k = 1, \dots, N\}$$

Az általános prediktív alak:

$$\hat{y}(k|\theta) = g(k, D[1, k-1]; \theta)$$

Paraméterekben lineáris rendszerek:

$$\hat{y}(k|\theta) = \theta^T g^*(k, D[1, k-1])$$

*Példa:* ARX modell

$$\hat{y}(k|\theta) = -a_1 y(k-1) - \dots - a_n y(k-n) + b_0 u(k) + \dots + b_m u(k-m)$$

$$\theta = [-a_1 \ \dots \ -a_n \ b_0 \ \dots \ b_m]^T$$

$$g^*(k, D[1, k-1]) = \varphi(k) = [y(k-1) \ \dots \ -y(k-n) \ u(k) \ \dots \ u(k-m)]$$



## Példa: paraméterben lineáris nemlineáris eset

---

Paraméterekben lineáris nemlineáris ARX modell, amikor *a kimeneti rendszerzaj fehér.*

$$y(k) = a_1 y^2(k-1) + b_0 u^4(k) + e(k)$$

Az általános nemlineáris prediktív alak:

$$\theta = [a_1 \ b_0]^T, \quad \hat{y}(k|\theta) = y(k) - e(k)$$

Segédváltozókkal:

$$y^2(k-1) = z(k-1), \quad u^4(k) = w(k)$$

a modell teljesen ARX alakra hozható:

$$\hat{y}(k|\theta) = a_1 z(k-1) + b_0 w(k)$$

$$\theta = [a_1 \ b_0]^T$$

## A predikációs hiba

Eloállítható a *predikációs hiba sorozat* a modellbol és a mért érték sorozatból:

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

**A paraméterbecslés elve:** Egy paraméterbecslési módszer a mért érték sorozatból eloállít egy becsült paraméter vektort:

$$D^N \rightarrow \hat{\theta}_N$$

*Egy modell "jó", azaz a becsült paraméterek "jó", ha a predikációs hibák "kicsik".*

### A predikációs hiba nagysága

Az  $\varepsilon(k, \theta)$  predikációs hiba egy jelsorozat, nagyságát *jelnormával* mérjük.

# A predikciós hiba nagysága

## Eloszurés

*A predikciós hiba eloszurésére akkor van szükség, ha a predikciós hibasorozat tagjai korreláltak, azaz nem tekinthetők fehérzajnak.*

## A norma megválasztása

$$V_N(\theta, D^N) = \frac{1}{N} \sum_{i=1}^N \ell(\varepsilon(k, \theta))$$

ahol  $\ell(\cdot)$  egy pozitív skalár értékű függvény.

*Egykimenetű eset: legegyszerűbb és legelterjedtebb a négyzetes jelnorma*

$$\ell(\varepsilon) = \frac{1}{2} \varepsilon^2$$

## A predikciós hiba nagysága - 2

### A norma megválasztása bonyolultabb esetekben

*Súlyozott eset: nem egyenlően pontos mérések*

$$V_N(\theta, D^N) = \frac{1}{N} \sum_{k=1}^N \beta(N, k) \ell(\varepsilon(k, \theta))$$

ahol  $\beta(N, k)$  időtől függő súlytényező sorozat.

*Többkimenetű eset: általánosított négyzetes jelnorma*

$$\ell(\varepsilon) = \frac{1}{2} \varepsilon^T \Lambda^{-1} \varepsilon$$

## A predikciós hiba minimalizálása

A paraméterbecslési módszer:  $D^N \rightarrow \hat{\theta}_N$

### Az általános paraméterbecslési feladat:

Adottak

- mért értékek:  $D[1, N] = D^N = \{(y(k), u(k)) \mid k = 1, \dots, N\}$
- prediktív parametrizált modell:  $\hat{y}(k|\theta) = g(k, D[1, k-1]; \theta)$   
predikciós hiba sorozat (diszkrét idejű jel):  $\varepsilon(k, \theta) = y(k) - \hat{y}(k|\theta)$ ,  $k = 1, \dots, N$
- norma a predikciós hibán:  $V_N(\theta, D^N) = \frac{1}{N} \sum_{k=1}^N \ell(\varepsilon(k, \theta))$  ahol  $\ell(\cdot)$  egy pozitív skalár értékű függvény, leggyakrabban:  $\ell(\varepsilon) = \frac{1}{2}\varepsilon^2$

*Az ismert  $D^N$  mért érték sorozatból és a  $\theta$  paraméter vektor értékéből kiszámíthatjuk a  $V_N(\theta, D^N)$  norma értékét. A  $k = N$  idopillanatban válasszuk meg a becsült  $\hat{\theta}_N$  paraméter vektort úgy, hogy*

$$\hat{\theta}_N = \hat{\theta}_N(D^N) = \arg \min_{\theta} V_N(\theta, D^N)$$

## Példa: SISO ARX modellek

**ALAPESET:** Az általános alakú input-output modellben a mozgóátlag tag nulla, azaz *a kimeneti rendszerzaj fehér*

$$A^*(q^{-1})y(k) = B^*(q^{-1})u(k) + e(k)$$

A modell prediktív alakja:

$$\hat{y}(k|\theta) = -a_1y(k-1) - a_2y(k-2) \cdots - a_ny(k-n) + b_0u(k) + \cdots + b_mu(k-m)$$

A paramétervektor:

$$\theta = [-a_1 \quad -a_2 \quad \cdots \quad -a_n \quad b_0 \quad b_1 \quad \cdots \quad b_m]^T$$

A predikciós hiba (**fehérzaj!**):

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

# *A LEGKISEBB NÉGYZETES (LKN) BECSLÉS*

## A legkisebb négyzetes hibájú becslők

Egykimenetű eset, négyzetes jelnorma:

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

A keresett paramétervektor és a mért kimenetek vektora

$$\theta^T = [\theta_1 \ \theta_2 \ \dots \ \theta_m] \quad , \quad y^T = [y(1) \ y(2) \ \dots \ y(N)]$$

Prediktív modell:

$$\hat{y}(k|\theta) = f(\theta, k) \quad , \quad V_N(\theta, D^N) = \frac{1}{N} \sum_{k=1}^N \frac{1}{2} [y(k) - f(k, \theta)]^2$$

$$\frac{1}{N} \sum_{k=1}^N [y(k) - f(k, \theta)] \frac{\partial f(k, \theta)}{\partial \theta_j} = 0 \quad , \quad j = 1, \dots, m$$

(A fenti egyenletrendszert kell megoldani  $\theta$ -ra.)



*Paraméterekben lineáris modell esetén:*

$$\hat{y}(k|\theta) = \theta^T \varphi(k)$$

ahol  $\varphi(\cdot)$  az úgynevezett *regresszor*, a mért adatokat tartalmazza;  $\theta$  a becsülni kívánt állandó modellparaméterek vektora.

A predikciós hiba:

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

A minimalizálandó kritériumfüggvény:

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

## LKN becslés paraméterekben lineáris esetben

---

Elvégezve a parciális deriválásokat a paramétervektor elemei szerint:

$$\frac{1}{N} \sum_{k=1}^N \varphi(k) [y(k) - \varphi^T(k)\theta] = 0$$

Ebből:

$$\frac{1}{N} \sum_{k=1}^N \varphi(k)y(k) = \frac{1}{N} \sum_{k=1}^N \varphi(k)\varphi^T(k)\theta$$

aminek megoldása  $\theta$ -ra adja az LS- vagy LKN-becslést:

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

## Példa: paraméterben lineáris nemlineáris eset

---

Paraméterekben lineáris ARX modell, amikor a *kimeneti rendszerzaj fehér*.

$$y(k) = a_1 y^2(k-1) + b_0 u^4(k) + e(k)$$

Az általános nemlineáris prediktív alak:

$$\theta = [a_1 \ b_0]^T, \quad \hat{y}(k|\theta) = y(k) - e(k)$$

Segédváltozókkal:

$$y^2(k-1) = z(k-1), \quad u^4(k) = w(k)$$

a modell teljesen ARX alakra hozható.

## Példa: ARX modellek paramétereinek LKN becslése

---

Az általános alakú input-output modellben a mozgóátlag tag nulla, azaz a *kimeneti rendszerzaj fehér*

$$A^*(q^{-1})y(k) = B^*(q^{-1})u(k) + e(k)$$

A modell prediktív alakja:

$$\hat{y}(k|\theta) = -a_1y(k-1) - a_2y(k-2) \cdots - a_ny(k-n) + b_0u(k) + \cdots + b_mu(k-m)$$

A paramétervektor:

$$\theta = [-a_1 \quad -a_2 \quad \cdots \quad -a_n \quad b_0 \quad b_1 \quad \cdots \quad b_m]^T$$

A regresszor:

$$\varphi(k) = [y(k-1) \quad y(k-2) \quad \cdots \quad y(k-n) \quad u(k) \quad u(k-1) \quad \cdots \quad u(k-m)]^T$$

# *A LKN BECSLÉS ASZIMPTOTIKUS TORZÍTATLANSÁGA*

## Prediktív modellek paramétereinek LKN becslésének tulajdonságai 1.

---

*Eltérés a standard lineáris regressziótól: a  $\varphi(k)$  regresszor vektorban szereplő jelek között a kimenet mért értékei is szerepelnek  $\implies$  az egyes  $y(k)$  mért értékeket még ARX modell esetén sem csak független fehér mérési hiba terheli a determinisztikus modellhez képest.*

### **A becslés aszimptotikus viselkedése**

$$y(k) = \theta_0^T \varphi(k) + \nu_0(k)$$

modellel leírható rendszer,  $\{\nu_0(k)\}$  hibasorozattal,  $\theta_0$  a paraméter úgynevezett *nominális értéke* vagy "valódi érték"e.

LKN becslés és jelölés

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

## Prediktív modellek paramétereinek LKN becslésének tulajdonságai 2.

---

$$\hat{\theta}_{LS}(N) = [R(N)]^{-1} \frac{1}{N} \sum_{k=1}^N \varphi(k) [\varphi(k)^T \theta_0 + \nu_0(k)]$$

$$\hat{\theta}_{LS}(N) = \theta_0 + [R(N)]^{-1} \frac{1}{N} \sum_{k=1}^N \varphi(k) \nu_0(k)$$

A becslési hiba a fenti egyenlet második tagja. Azt szeretnénk,

- ha ez a tag "kicsi" lenne, hiszen ekkor lesz a becslött érték a valódi  $\theta_0$  értékhez közel, és azt,
- ha ez a tag tartana 0-hoz a minta elemszámának növelésével, azaz, ha  $N \rightarrow \infty$ .

*Egy becslés viselkedését a mintaelemszám növelésével a becslés **aszimptotikus viselkedés**-ének nevezik. Ilyen értelemben beszélhetünk például aszimptotikus torzítatlanságról.*

## Prediktív modellek paramétereinek LKN becslésének tulajdonságai 3.

---

Ha a  $\nu_0(k)$  hiba kicsi a  $\varphi(k)$  mért értékeket tartalmazó regresszorhoz képest, akkor a

$$[R(N)]^{-1} \frac{1}{N} \sum_{k=1}^N \varphi(k) \nu_0(k)$$

becslési hiba is kicsi lesz.

**Fontos:** Ha mind az  $(u(k), k = 1, 2, \dots)$  bemenet, mind a  $(\nu_0(k), k = 1, 2, \dots)$  hiba stacionárius folyamat szerint változik egy AR(MA)X modellben, akkor az  $(y(k), k = 1, 2, \dots)$  kimenet is stacionárius sztochasztikus folyamat lesz.



## Az aszimptotikus viselkedés vizsgálatának feltételei

---

A becslési hiba aszimptotikus viselkedésének vizsgálatához tegyük fel,  
hogy

1. a  $\{\nu_0(k)\}_{k=1}^N$  hiba egy stacionárius sztochasztikus sorozat (azaz diszkrét idejű sztochasztikus folyamat) egy realizációja,
2. a rendszer maga egy ARX modellel írható le,
3. magát az  $\{u(k)\}_{k=1}^N$  bemenetet is egy stacionárius sztochasztikus folyamat szerint változtatjuk.

## Az $R(N)$ mátrix elemei

$$R(N) = \frac{1}{N} \sum_{k=1}^N \varphi(k) \varphi^T(k)$$

ahol  $\varphi(k) = [y(k-1) \ y(k-2) \ \dots \ y(k-n) \ u(k) \ u(k-1) \ \dots \ u(k-m)]^T$   
 $R(N) = \frac{1}{N} \sum_{k=1}^N \cdot$

$$\left[ \begin{array}{ccc|ccc} y(k-1)y(k-1) & \dots & y(k-1)y(k-n) & y(k-1)u(k) & \dots & y(k-1)u(k-m) \\ y(k-2)y(k-1) & \dots & y(k-2)y(k-n) & y(k-2)u(k) & \dots & y(k-2)u(k-m) \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y(k-n)y(k-1) & \dots & y(k-n)y(k-n) & y(k-n)u(k) & \dots & y(k-n)u(k-m) \\ \text{---} & \text{---} & \text{---} & \text{---} & \text{---} & \text{---} \\ u(k)y(k-1) & \dots & u(k)y(k-n) & u(k)u(k) & \dots & u(k)u(k-m) \\ u(k-1)y(k-1) & \dots & u(k-1)y(k-n) & u(k-1)u(k) & \dots & u(k-1)u(k-m) \\ \dots & \dots & \dots & \dots & \dots & \dots \\ u(k-m)y(k-1) & \dots & u(k-m)y(k-n) & u(k-m)u(k) & \dots & u(k-m)u(k-m) \end{array} \right]$$

## $R(N)$ mátrix elemeinek aszimptotikus viselkedése 1.

---

A  $\varphi(\cdot)$  regresszor AR(MA)X esetben csak régebbi diszkrét idejű bemeneteket és kimeneteket tartalmaz, ezért az  $[R(N)]_{ij}$  elemek háromfélék lehetnek:

- *input autokovariancia*:  $r_{uu}(\tau)$  az  $\{u(k)\}_{k=1}^N$  sztochasztikus folyamat autokovariancia függvénye

$$\hat{R}_u^N(\tau) = \frac{1}{N} \sum_{k=1}^N u(k)u(k-\tau) \quad \rightarrow \quad R_u(\tau) = r_{uu}(\tau)$$

- *output autokovariancia*:  $r_{yy}(\tau)$  az  $\{y(k)\}_{k=1}^N$  sztochasztikus folyamat autokovariancia függvénye

$$\hat{R}_y^N(\tau) = \frac{1}{N} \sum_{k=1}^N y(k)y(k-\tau) \quad \rightarrow \quad R_y(\tau) = r_{yy}(\tau)$$

## $R(N)$ mátrix elemeinek aszimptotikus viselkedése 2.

- *input-output kovariancia*:  $r_{yu}(\tau)$  a két előző stacionárius sztochasztikus folyamat kereszt kovariancia fv-e

$$\hat{R}_{yu}^N(\tau) = \frac{1}{N} \sum_{k=1}^N y(k)u(k-\tau) \quad \rightarrow \quad R_{yu}(\tau) = r_{yu}(\tau)$$

Így az  $R(N)$  mátrix nagy mintaelemszámok esetén ( $N \rightarrow \infty$ ) egy konstans  $R^*$  mátrixhoz tart

A  $\{\nu_0(k)\}_{k=1}^N$  hiba folyamat is stacionárius, így

$$\frac{1}{N} \sum_{k=1}^N \varphi(k)\nu_0(k) \quad \rightarrow \quad h^*$$

$h^*$  konstans vektor az  $\{u(k)\}_{k=1}^N$  és  $\{\nu_0(k)\}_{k=1}^N$ , illetve az  $\{y(k)\}_{k=1}^N$  és  $\{\nu_0(k)\}_{k=1}^N$  sztochasztikus folyamatok kereszt kovariancia függvényeinek elemeit tartalmazza.

## Az aszimptotikus torzítatlanság feltételei

A becslési hiba aszimptotikusan torzítatlan **az aszimptotikus viselkedés vizsgálatának feltételei** fennállása esetén, ha

(i) az  $R^*$  mátrix nemszinguláris (**elegendő gerjesztés**)

Teljesül, ha az  $\{u(k)\}_{k=1}^N$  és  $\{\nu_0(k)\}_{k=1}^N$  folyamatok egymástól függetlenek, és az  $R_u(i-j)$  autokorrelációkból alkotott  $R_{ij}$  mátrix nemszinguláris. (elegendően gerjesztő bemenetnek)

(ii) a  $h^* = 0$  fennállása esetén

(iia) A  $\{\nu_0(k)\}_{k=1}^N$  **hiba nulla várható értékű fehérzaj sorozat:**

nincs modellezési hiba, és a mérési hiba nem színes (mérőrendszernek nincs dinamikája). Ekkor a  $\nu_0(k)$  hiba, mint valószínűségi változó független a múlttól, így az  $E[\varphi(k)\nu_0(k)]$  tagok mindegyike nulla.

(iib) Az  $\{u(k)\}_{k=1}^N$  bemenet egy nulla várható értékű fehérzaj sorozat, és a rendszer rendje  $n = 0$ : jelen kimenet nem függ a múltbeli kimenetektől. Ekkor a  $\varphi(k)$  regresszor csak a bemenet múltbeli értékeit tartalmazza, és így

$$E[\varphi(k)\nu_0(k)] = 0.$$

## Prediktív modellek paramétereinek LKN becslésének tulajdonságai 4.

---

Fontos megjegyezni, hogy a fenti (i) és (ii) feltételek fennállása esetén a

$$\sqrt{N}(\hat{\theta}_{LS}(N) - \theta_0)$$

valószínűségi változó aszimptotikus eloszlása olyan többdimenziós *normális* eloszlás lesz, amelynek várható értéke 0, kovariancia mátrixa pedig SISO esetben  $\lambda_0 [R^*]^{-1}$  ahol  $\lambda_0$  a  $\{\nu_0(k)\}_{k=1}^N$  hiba szórásnégyzete (varianciája).

# *A LKN BECSLÉS MIMO ESETBEN*

## LKN becslés a több bemenetű egy kimenetű esetben

---

A  $\varphi(\cdot)$  regresszor a skalár értékű  $y(\cdot)$  értékek mellett a vektor értékű  $u(k) \in \mathbb{R}^r, k = 1, \dots, N$  értékektől is függ. Ekkor az  $u(k)$  vektor minden egyes  $u_j(k)$  koordinátáját tekinthetjük egy-egy skaláris változónak, így a  $\varphi(\cdot)$  regresszor a

$$D^k = \{(y(i), u_1(i), \dots, u_r(i)) \mid i = 1, \dots, k\}$$

skaláris változóktól függőnek tekinthető és az egybemenetű egykimenetű esetre felírt LKN formula változtatás nélkül alkalmazható.



## Példa: Két bemenetű ARX modell

$$A^*(q^{-1})y(k) = B^*(q^{-1})u(k) + C^*(q^{-1})e(k)$$

alakú input-output modellben a mozgóátlag tag nulla, azaz a *kimeneti rendszerzaj fehér*, de tegyük fel, hogy két bemenetünk van, azaz  $u(k) \in \mathbb{R}^2$ .

$$y(k) = -a_1y(k-1) - a_2y(k-2) \cdots - a_ny(k-n) + b_0^T u(k) + \cdots + b_m^T u(k-m)$$

A paramétervektor:

$$\theta = [-a_1 \ -a_2 \ \dots \ -a_n \ b_{01} \ b_{02} \ b_{11} \ b_{12} \ \dots \ b_{m1} \ b_{m2}]^T$$

ahol  $b_{ij}$  az  $i$ -edik paramétervektor  $j$ -edik koordinátája, a regresszor pedig:

$$\varphi(k) = [y(k-1) \ y(k-2) \ \dots \ y(k-n) \ u_1(k) \ u_2(k) \ u_1(k-1) \ u_2(k-1) \ \dots \ u_1(k-m) \ u_2(k-m)]^T$$

## LKN becslés a több bemenetű több kimenetű esetben

A diszkrét idejű időinvariáns paraméterekben lineáris egy bemenetű egy kimenetű rendszermodellek alakja általánosítható több kimenet, azaz vektor értékű  $y(k) \in \mathbb{R}^p$  esetére is az alábbi formában ( $\hat{y}(k|P) = P^T \varphi(k)$ )

$$\hat{y}_1(k|P) = P_{11}\varphi_1(k) + P_{21}\varphi_2(k) + \cdots + P_{m1}\varphi_m(k)$$

...

$$\hat{y}_p(k|P) = P_{1p}\varphi_1(k) + P_{2p}\varphi_2(k) + \cdots + P_{mp}\varphi_m(k)$$

ahol most a  $P \in \mathbb{R}^{m \times p}$  mátrix  $j$ -edik oszlopába gyűjtöttük össze az  $y(k)$  vektor  $j$ -edik koordinátájára vonatkozó  $\theta^j$  modell paramétereit, azaz  $P_{ij} = \theta_i^j$ , és az egyes  $y_j(k)$  koordinátákra vonatkozó részmodelleknek **ugyanaz a regresszora**.

## Egyszerű példa

### Két bemenetű két kimenetű eset, ARX modell

$$y_1(k) = a_{11}y_1(k-1) + a_{12}y_2(k-1) + b_{11}u_1(k) + b_{12}u_2(k) + e_1(k)$$

$$y_2(k) = a_{21}y_1(k-1) + a_{22}y_2(k-1) + b_{21}u_1(k) + b_{22}u_2(k) + e_2(k)$$

A regresszor:

$$\varphi(k) = [y_1(k-1) \quad y_2(k-1) \quad u_1(k) \quad u_2(k)]^T$$

A paraméter mátrix:

$$P = \begin{bmatrix} a_{11} & a_{21} \\ a_{12} & a_{22} \\ b_{11} & b_{21} \\ b_{12} & b_{22} \end{bmatrix}$$

## LKN becslés a MIMO esetben 2.

---

### Becslés a több kimenetű esetben: 1. esetőség

*Ha az  $y(k)$  vektor koordinátáira vonatkoztatott predikációs hibák egymástól teljesen függetlenek, akkor a paraméterbecslést egymástól függetlenül elvégezhetjük a részmodellekre az **egy kimenetű esetre vonatkozó LKN formulával**.*

Ekkor a  $P$  paraméter mátrix oszlopaira (az abban szereplő  $\theta^j$  részmodell paraméterekre) kapunk egymástól független becslést.

## LKN becslés a MIMO esetben 3.

### Becslés a több kimenetű esetben: 2. eshetőség

*Ha az egyes koordinátákra vonatkozó predikciós hibák nem függetlenek, akkor együttes regressziós becslést kell végeznünk:*

$$y^* = \begin{bmatrix} y_1(1) \\ \dots \\ y_p(1) \\ \dots \\ y_1(N) \\ \dots \\ y_p(N) \end{bmatrix}, \quad p^* = \begin{bmatrix} P_{11} \\ \dots \\ P_{1m} \\ \dots \\ P_{p1} \\ \dots \\ P_{pm} \end{bmatrix}, \quad X^* = \begin{bmatrix} X & 0 & \dots & 0 \\ 0 & X & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & X \end{bmatrix}$$

ahol  $y_i(j)$  az  $j$ -edik mért kimenet vektor  $i$ -edik koordinátája.