

*Dinamikus rendszerek paramétereinek becslése*  
*Valószínűségszámítás, matematikai statisztika*  
*(ismétlés)*  
*Predikciós hiba minimalizálásán alapuló*  
*paraméterbecslés*

**Hangos Katalin**

MTA SzTAKI, Folyamatirányítási Kutató Csoport

PE Számítástudomány Alkalmazása Tanszék

# VALÓSZÍNŰSÉGSZÁMÍTÁS *(ismétlés)*

# Skalár értékű valószínűségi változók

A  $\xi$  valószínűségi változó *normális vagy Gauss eloszlású*, jelölésben

$$\xi \sim \mathbb{N}(m, \sigma^2) \quad (1)$$

ha a változó  $f_\xi$  valószínűségi sűrűségfüggvénye:

$$f_\xi(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (2)$$

ahol  $m$  a változó *várható értéke* és  $\sigma^2$  a *szórása*

Az  $f_\xi$  sűrűségfüggvényű  $\xi$  valószínűségi változó *várható értéke* és *szórásnégyzete*

$$E\{\xi\} = \int x f_\xi(x) dx \quad , \quad \sigma^2\{\xi\} = \int (x - E\{\xi\})^2 f_\xi(x) dx$$

## Kovariancia

Két skalár értékű valószínűségi változó  $\xi$  és  $\theta$  kovarianciája:

$$COV\{\xi, \theta\} = E\{(\xi - E\{\xi\})(\theta - E\{\theta\})\}$$

A  $\xi$  skalár értékű valószínűségi változó *varianciája* (a változó önmagával vett kovarianciája):

$$\sigma^2\{\xi\} = COV\{\xi, \xi\} = E\{(\xi - E\{\xi\})^2\}$$

*Korrelációs együttható* (normált kovariancia):

$$\rho\{\xi, \theta\} = \frac{E\{(\xi - E\{\xi\})(\theta - E\{\theta\})\}}{\sigma\{\xi\}\sigma\{\theta\}}$$

## Vektor értékű valószínűségi változók

A  $\xi$  valószínűségi változó vektor értékű, ha

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

A változó  $m \in \mathbb{R}^\mu$  várható értéke egy valós vektor.

Varianciája egy valós elemű négyzetes mátrix, az ún. *kovariancia mátrix*:

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

A kovariancia mátrixok pozitív definit szimmetrikus mátrixok, azaz

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

## Együttes valószínűségi sűrűségfüggvény

A  $\xi_1, \dots, \xi_n$  skalár értékű valószínűségi változók együttes valószínűségi sűrűségfüggvénye egy  $n$  változós nem-negatív függvény  $f(x_1, \dots, x_n)$ , amelyre

$$P[a_1 \leq x_1 \leq b_1, \dots, a_n \leq x_n \leq b_n] = \int_{a_1}^{b_1} \dots \int_{a_n}^{b_n} f(x_1, \dots, x_n) dx_1 \dots dx_n$$

Marginális valószínűségi sűrűségfüggvény (a 2 változós esetben)

$$f_{\xi_1}(x_1) = \int_{-\infty}^{\infty} f_{\xi_1, \xi_2}(x_1, x_2) dx_2$$

**Függetlenség** (a 2 változós esetben)

$$f_{\xi_1, \xi_2}(x_1, x_2) = f_{\xi_1}(x_1) \cdot f_{\xi_2}(x_2)$$

## Többdimenziós normális eloszlás

**A normális vagy Gauss eloszlású  $m$  várható értékű és  $\Sigma$  kovariancia mátrixú valószínűségi változó**

$$\xi \sim N(m, \Sigma)$$

egy olyan valószínűségi változókból álló vektor, amelynek minden  $\xi_i, i = 1, \dots, \mu$  komponense egy normális eloszlású skalár értékű valószínűségi változó.


Valószínűségi sűrűségfüggvény:  $R$  a  $\rho_{ij}$  korrelációs e.h.-kból alkotott determináns

$$f(x_1, \dots, x_\mu) = \frac{1}{\sqrt{2\pi}\sigma_1 \dots \sigma_\mu \sqrt{R}} e^{-\frac{1}{2R} \left( \sum_{i=1}^{\mu} \sum_{j=1}^{\mu} \rho_{ij} \frac{(x_i - m_i)(x_j - m_j)}{\sigma_1 \sigma_2} \right)}$$

# Két dimenziós normális eloszlás

Valószínűségi sűrűségfüggvény:

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-r^2}} e^{-\frac{1}{2(1-r^2)} \left( \frac{(x_1-m_1)^2}{\sigma_1^2} - 2r \frac{(x_1-m_1)(x_2-m_2)}{\sigma_1\sigma_2} + \frac{(x_2-m_2)^2}{\sigma_2^2} \right)}$$





## Lineárisan transzformált valószínűségi változók

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:

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

*Ha a  $\xi$  valószínűségi változó  $N(m_\xi, \Delta_\xi)$  normális eloszlású volt,  $m_\xi$  várható értékkel és  $\Delta_\xi$  kovariancia mátrixszal, akkor  $\eta$  transzformált valószínűségi változó is  $N(m_\eta, \Delta_\eta)$  normális eloszlású lesz, ahol*

$$m_\eta = Tm_\xi \quad , \quad \Delta_\eta = T\Delta_\xi T^T$$

# *LINEÁRIS REGRESSZIÓ (ismétlés)*

# Paraméterbecslés lineáris regresszióval 1.

## Feladatkitűzés

Adott:

- Egy paraméterekben lineáris determinisztikus modell

$$y^{(M)} = x^T p = \sum_{i=1}^n x_i p_i$$

$p \in R^n$  az ismeretlen modell paraméterek, a determinisztikus független változók  $x \in R^n$  és az  $y^{(M)} \in R^\mu$  mérési hibával terhelt függő változó.

- Az  $m$  ( $m \geq \mu$ ) mérésből álló mért értékek halmaza

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_m \end{bmatrix}, \quad X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix}$$

# Paraméterbecslés lineáris regresszióval 1f.

- Egy  $L$  veszteségfüggvény

$$L = r^T W r = \sum_{i=1}^m \sum_{j=1}^m r_i W_{ij} r_j$$
$$r_i = y_i - y_i^{(M)} = y_i - x^{(i)T} p$$

ahol  $r$  a *reziduál vagy eltérés vektor* és  $W$  egy alkalmas *pozitív definit szimmetrikus súlymátrix*.

*Feladat:*

Számítsuk ki a  $p$  paraméterek egy  $\hat{p}$  becslését úgy, hogy az  $L$  veszteségfüggvény minimális legyen.

$$L \text{ minimuma: } \frac{\partial L}{\partial p} = 0$$

$$(r^T W) r' = 0$$

$$(y - X^T p)^T W X^T = 0$$

$$X^T W y = X^T W X p$$

## Paraméterbecslés lineáris regresszióval 2.

**Módszer:** A  $p$  paraméterek legkisebb négyzetes (LS) becslése:

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

### Megjegyzések:

1. Feltételezzük, hogy mért függő változók értékét *additív, nulla várható értékű mérési hiba* terheli

$$y_i = y_i^{(M)} + \varepsilon_i \quad (i = 1, \dots, m) \quad , \quad E\{\varepsilon_i\} = 0$$

Ha még az egyes *mérési hibák egymástól statisztikailag függetlenek es azonos normális eloszlásúak*  $\Delta_\varepsilon$  kovariancia mátrixszal, akkor a mért értékek eloszlása is normális lesz:

$$y \sim N(y^{(M)}, \Delta_\varepsilon)$$

2. A súlymátrix egy jó választása, ha az a mérési hibák ismert vagy becsült kovariancia mátrixának inverze:

$$W = \Delta_\varepsilon^{-1}$$

## A regresszióval kapott paraméterek tulajdonságai

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

becslési egyenletet tekinthetjük úgy is, mint az  $y$  valószínűségi változó egy lineáris transzformációját a  $T = (X^T W X)^{-1} X^T$  konstans determinisztikus mátrixszal, amelynek eredménye a  $\hat{p}$  valószínűségi változó.

Ennek alapján a  $\hat{p}$  becslés várható értéke és  $COV\{\hat{p}\} = T COV\{y\} T^T$  szórása kiszámolható.

*Ha a mérési hibák normális eloszlásúak nulla várható értékkel és  $\Delta_\varepsilon$  kovariancia mátrixszal, és a súlymátrixot a  $\Delta_\varepsilon^{-1}$ -nek választjuk, akkor a  $\hat{p}$  becslés az alábbi tulajdonságokkal rendelkezik:*

- *A becslés normális eloszlású.*
- *A becslés várható értéke  $E\{\hat{p}\} = p$ , tehát a becslés torzítatlan.*
- *A becslés kovariancia mátrixa*

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

- *A becslés egy maximum likelihood vagy legnagyobb valószínűségű becslés, és így egy hatásos optimális becslés*

# *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  $W_u(q^{-1}, \theta)$  tényezők úgynevezett *lineáris szűrők*, a  $\theta$  az állandó, ismeretlen, becsülni kívánt paraméterek vektora.

A diszkrét idejű lineáris időinvariáns egybemenetű-egykimenetű (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 becslo 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 időinvariáns 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

Előállítható a *predikációs hiba sorozat* a modellből 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 előállít egy becsült paraméter vektort:

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

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

### A predikációs hiba nagysága

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

# A predikciós hiba nagysága

## Előszűrés

*A predikciós hiba előszűrésére 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 értéket. A  $k = N$  időpillanatban 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!**):

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