

*Dinamikus rendszerek paramétereinek becslése*

*A maximum likelihood (ML) becslés*

*A becsült paraméterek kovariancia mátrixa*

**Hangos Katalin**

PE Villamosmérnöki és Információs Rendszerek Tanszék

# *ISMÉTLÉS*

## 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)

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

## Kovariancia mártixok

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

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

# Két dimenziós normális eloszlás

Valószínűségi sűrűségfüggvény:

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



## A predikciós hiba minimalizálása

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

**Feladatkitűzés:** Adott

- 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!**):

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

## 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 minimalizálása  $\theta$  függvényében adja a LKN-becslést:

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



# *A MAXIMUM LIKELIHOOD (ML) BECSLÉS*

# Valószínűségi modellen alapuló becslések

Cél: egy ismeretlen  $\theta$  paraméter becslése

Adottak:

- A paraméterről információt hordozó  $S(y^N) = \{y(1), \dots, y(N)\}$  megfigyelések (skalár értékű valószínűségi változók) *nem feltétlenül függetlenek, és azonos eloszlásúak*
- Ezek együttes valószínűségi sűrűségfüggvénye

$$f(\theta; x_1, \dots, x_N) = f_y(\theta; x^N) \quad , \quad f_y : \mathbb{R}^d \times \mathbb{R}^N \rightarrow \mathbb{R}$$

amely függ az ismeretlen  $\theta \in \mathbb{R}^d$  paramétertől,

- A paraméter becslésére konstruált *becslő*:  $\hat{\theta}(y^N)$ ,  $\hat{\theta} : \mathbb{R}^N \rightarrow \mathbb{R}^d$  egy  $N$ -változós  $d$  dimenziós vektor értékű függvény.

A  $y_*^N$  konkrét megfigyelt értékeket, amelyek determinisztikusak a fenti becslő formulába behelyettesítve kapjuk a paraméter  $\hat{\theta}_* = \hat{\theta}(y_*^N)$  becslését.

## A maximum likelihood becslés elve

---

Az úgynevezett **maximum likelihood becselő** a megfigyelt esemény valószínűségét maximalizálja.

A megfigyelt mitelemek  $f_y$  együttes valószínűségi sűrűségfüggvénye a konkrét megfigyelt  $y_*^N$  értékek behelyettesítése után az ismeretlen  $\theta$  paraméter egy determinisztikus függvénye, amelyet

$$\ell(\theta; y_*^N) = f_y(\theta; y_*^N)$$

*likelihood függvénynek* nevezünk.

A *maximum likelihood becslés* az a

$$\hat{\theta}_{ML}(y_*^N) = \arg \max_{\theta} f_y(\theta; y_*^N)$$

érték, amely az együttes valószínűségi sűrűségfüggvényt maximalizálja.

## A ML becslés normális eloszlás esetén

---

Normális eloszlású val. változók esetén az együttes eloszlás is normális lesz, ezért a gyakorlatban a fenti maximalizálás helyett a

$$\arg \max_{\theta} \ell(\theta; y_*^N) \equiv \arg \min_{\theta} [-\ln [\ell(\theta; y_*^N)]]$$

minimalizálást szoktuk elvégezni úgy, hogy

$$\frac{d \ln(\ell)}{d\theta} = 0$$

legyen ahol  $\ln(\cdot)$  a természetes alapú logaritmusfüggvény.

## A ML becslés független és azonos eloszlású megfigyelésekre

---

Ha az  $S(y^N)$  mintában szereplő mintaelemek független és azonos eloszlású valószínűségi változók, akkor együttes valószínűségi sűrűségfüggvényük a sűrűségfüggvények szorzata:

$$\ell(\theta; y_*^N) = \prod_{i=1}^N f_{y(i)}(\theta; y_{*i}) = \prod_{i=1}^N f_y(\theta; y_{*i})$$

Ekkor a *log-likelihood függvény* összeg alakú:

$$\ln[\ell(\theta; y_*^N)] = \sum_{i=1}^N \ln f_y(\theta; y_{*i})$$

## Példa: Egy egyszerű maximum likelihood becslés 1.

---

**Minta:** független skalár értékű normális eloszlású, azonos, de ismeretlen  $\theta_0$  várható értékű és mintaelemenként különböző  $\lambda_i$  szórásnégyzetű  $y(i)$  valószínűségi változók:

$$y(i) \sim \mathbb{N}(\theta_0, \lambda_i)$$

Az ismeretlen várható érték becslése *mintaközéppel*:

$$\hat{\theta}_{SM}(y^N) = \frac{1}{N} \sum_{i=1}^N y(i)$$

A mintaelemek független normális eloszlású val. változók a

$$f_{y(i)}(x_i) = \frac{1}{\sqrt{2\pi\lambda_i}} e^{-\frac{(x_i - \theta)^2}{2\lambda_i}}$$

## Példa: Egy egyszerű maximum likelihood becslés 2.

Az együttes sűrűségfüggvény:

$$f_y(\theta; x^N) = \prod_{i=1}^N \left( \frac{1}{\sqrt{2\pi\lambda_i}} e^{-\frac{(x_i - \theta)^2}{2\lambda_i}} \right)$$

A log-likelihood függvényt minimalizáljuk  $\theta$  függvényében:

$$\hat{\theta}_{ML}(y^N) = \arg \min_{\theta} \ln f_y(\theta; y^N) = \arg \min_{\theta} \left\{ -\frac{N}{2} \ln 2\pi - \sum_{i=1}^N \frac{1}{2} \ln \lambda_i + \frac{1}{2} \sum_{i=1}^N \frac{(y(i) - \theta)^2}{\lambda_i} \right\}$$

A ML becslés:

$$\hat{\theta}_{ML}(y^N) = \frac{1}{\sum_{i=1}^N (1/\lambda_i)} \sum_{i=1}^N \frac{y(i)}{\lambda_i}$$

A maximum likelihood becslés figyelembe veszi a mintaelemek szórására vonatkozó információt is, és egy súlyozott mintaközepet használ becslőként.

# Prediktív modellek paramétereinek ML becslése 1.

---

## A teljes valószínűségi modell

$$\begin{aligned} \mathbb{M}(\theta) : \quad & \hat{y}(k | \theta) = g(k, D^{k-1}; \theta) \\ & \varepsilon(k, \theta) = y(k) - \hat{y}(k | \theta) \text{ függetlenek,} \\ & \text{adott } f_{\varepsilon}(\mathbf{x}; \mathbf{k}; \theta) \text{ sűrűségfüggvénnyel} \end{aligned}$$

## A likelihood függvény és a maximum likelihood becslés

A  $\varepsilon(k, \theta)$  hibák függetlenek, így az együttes sűrűségfüggvény:

$$\hat{f}_y(\theta; y^N) = \prod_{i=1}^N f_{\varepsilon}(y(i) - g(i, D^{i-1}; \theta), i; \theta) = \prod_{i=1}^N f_{\varepsilon}(\varepsilon(i, \theta), i; \theta)$$

a log-likelihood függvény pedig

$$\ell(\varepsilon, \theta, k) = -\ln f_{\varepsilon}(\varepsilon, k; \theta)$$



## Prediktív modellek paramétereinek ML becslése 2.

---

A ML becslés:

$$\hat{\theta}_{ML}(y^N) = \arg \min_{\theta} \frac{1}{N} \sum_{i=1}^N -\ell(\varepsilon(i, \theta), i; \theta)$$

A LKN becslés:

$$\hat{\theta}_{ML}(y^N) = \arg \min_{\theta \in D_M} V_N(\theta, y^N) \quad , \quad V_N(\theta, D^N) = \frac{1}{N} \sum_{k=1}^N \frac{1}{2} \varepsilon(k, \theta)^2$$

Látható, hogy a ML becslés a LKN becslés abban a speciális esetben, ha a veszteségfüggvényt a

$$V_N(\theta, y^N) = \frac{1}{N} \sum_{i=1}^N -\ln f_{\varepsilon}(\varepsilon(i, \theta), i; \theta)$$

alakúra választjuk.

## Példa: ARX modell paramétereinek ML becslése 1.

---

$$\hat{y}_t = ay_{k-1} + bu_{k-1}$$

$$\theta = \begin{bmatrix} a \\ b \end{bmatrix}$$

$\varepsilon(k, \theta) = y_k - ay_{k-1} - bu_{k-1} := e(k)$  függetlenek

$$f_e(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}} \text{ normális eloszlásúak}$$

Ekkor a mintaelemek együttes eloszlásfüggvénye:

$$\bar{f}_y(\varepsilon) = \prod_{k=1}^N f_e(y_k - ay_{k-1} + bu_{k-1}) = \prod_{k=1}^N \frac{1}{\sigma\sqrt{2\pi}} \exp\left(\frac{-(y_k - ay_{k-1} - bu_{k-1})^2}{2\sigma^2}\right)$$

## Példa: ARX modell paramétereinek ML becslése 2.

A log-likelihood függvény:

$$\ln \bar{f}_y(\theta; y^N) = \sum_{k=1}^N -\ln \left( \frac{1}{\sigma\sqrt{2\pi}} \right) + \ln \left( \exp \left( -\frac{(y_k - ay_{k-1} - bu_{k-1})^2}{2\sigma^2} \right) \right)$$

amely a paraméterek kvadratikus függvénye. Ennek egyértelmű minimuma:

$$\frac{d}{d\theta} \ln \bar{f}_y(\theta, y^N) = \begin{bmatrix} \sum_{k=1}^N 2y_{k-1} \frac{y_k - ay_{k-1} - bu_{k-1}}{2\sigma^2} \\ \sum_{k=1}^N 2u_{k-1} \frac{y_k - ay_{k-1} - bu_{k-1}}{2\sigma^2} \end{bmatrix} = 0$$

Az  $a$  és  $b$  paraméterek ML becslését az alábbi lineáris egyenletrendszer megoldása adja:

$$\begin{aligned} \sum_{k=1}^N 2y_{k-1} \frac{y_k - ay_{k-1} - bu_{k-1}}{2\sigma^2} &= 0 \\ \sum_{k=1}^N 2u_{k-1} \frac{y_k - ay_{k-1} - bu_{k-1}}{2\sigma^2} &= 0 \end{aligned}$$

*A BECSÜLT PARAMÉTEREK KOVARIANCIA  
MÁTRIXA:  
A CRAMÉR-RAO EGYENLŐTLENSÉG ÉS A FISHER  
INFORMÁCIÓS MÁTRIX*

# Cramér-Rao egyenlőtlenség, Fisher információs mátrix

---

A becsült  $\hat{\theta}$  paraméterek "jósága" (torzítatlan becslés!)

$$P = E \left[ \hat{\theta}(y^N) - \theta_0 \right] \left[ \hat{\theta}(y^N) - \theta_0 \right]^T$$

kovariancia mátrix (valamilyen normában mért) nagysága

- Cramér-Rao egyenlőtlenség a kovariancia mátrixra
- Fisher információs mátrix: alsó korlát értéke

# Cramér-Rao egyenlőtlenség

**1. Tétel (Cramér-Rao).** Legyen a  $\hat{\theta}(y^N)$  a  $\theta$  paraméter egy torzítatlan becslése úgy, hogy  $E[\hat{\theta}(y^N)] = \theta_0$  a paraméter valódi értéke, és az  $y^N$  minta elemeinek együttes valószínűségi sűrűség függvénye  $f_y(\theta_0; y^N)$ . Ekkor a  $\hat{\theta}(y^N)$  becslés kovariancia mátrixára az alábbi egyenlőtlenség érvényes:

$$E \left[ \hat{\theta}(y^N) - \theta_0 \right] \left[ \hat{\theta}(y^N) - \theta_0 \right]^T \geq M^{-1}$$

ahol  $M$  az úgynevezett **Fisher információs mátrix**:

$$\begin{aligned} M &= E \left[ \frac{d}{d\theta} \ln f_y(\theta; y^N) \right] \left[ \frac{d}{d\theta} \ln f_y(\theta; y^N) \right]^T \Bigg|_{\theta=\theta_0} = \\ &= -E \left[ \frac{d^2}{d\theta^2} \ln f_y(\theta; y^N) \right] \Bigg|_{\theta=\theta_0} \end{aligned}$$

# ARX modell példa: Fisher információs mátrix 1

$$\hat{y}_t = ay_{k-1} + bu_{k-1}$$

$$\theta = \begin{bmatrix} a \\ b \end{bmatrix}$$

$\varepsilon(k, \theta) = y_k - ay_{k-1} - bu_{k-1} := e(k)$  függetlenek

$$f_e(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}} \text{ normális eloszlásúak}$$

példában szereplő egyszerű ARX rendszert a  $\theta_0 = [a_0 \ b_0]^T$  valódi paramétervektorral. A becslés Fischer információs mátrixa:

$$M = E \begin{bmatrix} m_{aa} & m_{ab} \\ m_{ab} & m_{bb} \end{bmatrix}$$

## ARX modell példa: Fisher információs mátrix 2

A Fisher információs mátrix elemei

$$m_{aa} = \left( \sum_{k=1}^N 2y_{k-1} \frac{y_k - a_0 y_{k-1} - b_0 u_{k-1}}{2\sigma^2} \right)^2$$

$$m_{ab} = \left( \sum_{k=1}^N 2y_{k-1} \frac{y_k - a_0 y_{k-1} - b_0 u_{k-1}}{2\sigma^2} \right) \left( \sum_{k=1}^N 2u_{k-1} \frac{y_k - a_0 y_{k-1} - b_0 u_{k-1}}{2\sigma^2} \right)$$

$$m_{bb} = \left( \sum_{k=1}^N 2u_{k-1} \frac{y_k - a_0 y_{k-1} - b_0 u_{k-1}}{2\sigma^2} \right)^2$$

Az  $m_{aa}$ ,  $m_{ab}$ ,  $m_{bb}$  elemekben az  $\{y(k)\}_{k=1}^N$  és az  $\{u(k)\}_{k=1}^N$  sztochasztikus folyamatok negyedrendű auto- és keresztkorrelációs együtthatói állnak.



# A ML becslés aszimptotikus tulajdonságai 1

**2. Tétel (Wald-Cramér).** *Tegyük fel, hogy az  $\{y(i)\}_{i=1}^N$  függetlenek és azonos eloszlásúak úgy, hogy együttes sűrűségfüggvényük*

$$f_y(\theta; x_1, \dots, x_N) = \prod_{i=1}^N f_{y(i)}(\theta; x_i)$$

*és az  $y^N$  mintaelemek együttes sűrűségfüggvénye az  $f_y(\theta_0; x^N)$  valamely  $\theta_0$  valódi paraméter vektorral. Ekkor a  $\hat{\theta}_{ML}(y^N)$  ML becslés 1 valószínűséggel  $\theta_0$ -hoz tart, ha  $N$  tart a végtelenhez, és a*

$$\sqrt{N}[\hat{\theta}_{ML}(y^N) - \theta_0]$$

*eloszlása egy normális, 0 várható értékű és  $M^{-1}$  kovariancia mártixú eloszláshoz tart.*

## A ML becslés aszimptotikus tulajdonságai 2

---

Ugyanilyen tétel áll fenn abban az esetben is, ha dinamikus rendszerek paramétereinek becslésére alkalmazzuk a maximum likelihood becslést.

Így tehát *a maximum likelihood becslés - elméleti szempontból legalábbis - a lehetséges legjobb becslés.*

*DINAMIKUS RENDSZEREK  
PARAMÉTERBECSLÉSÉNEK KOVARIANCIA  
MÁTRIXA*

# A Fisher információs mátrix kiszámítása

Adott

- a teljes valószínűségi modell

$$\begin{aligned} \mathbb{M}(\theta) : \quad & \hat{y}(k | \theta) = g(k, D^{k-1}; \theta) \\ & \varepsilon(k, \theta) = y(k) - \hat{y}(k | \theta) \text{ függetlenek,} \\ & \text{adott } f_\varepsilon(x; k; \theta) \text{ sűrűségfüggvénnyel} \end{aligned}$$

- a szorzat alakú likelihood függvény

$$\bar{f}_y(\theta; y^N) = \prod_{i=1}^N f_\varepsilon(y(i) - g(i, D^{i-1}; \theta), i; \theta) = \prod_{i=1}^N f_\varepsilon(\varepsilon(i, \theta), i; \theta)$$

# 1. a log-likelihood függvény egyszerűbb alakja

---

$$\ell_0(\varepsilon) = \ln f_\varepsilon(\varepsilon)$$

$$\ln \bar{f}_y(\theta, y^N) = \sum_{i=1}^N \ln f_\varepsilon(\varepsilon(i, \theta)) = \sum_{i=1}^N -\ell_0(\varepsilon(i, \theta))$$

$$\frac{d}{d\theta} \ln \bar{f}_y(\theta, y^N) = \sum_{i=1}^N -\ell'_0(\varepsilon(i, \theta)) \cdot \underbrace{\frac{d}{d\theta} \varepsilon(i, \theta) \cdot (-1)}_{\Psi(i, \theta)}$$

## 2. behelyettesítés a Fisher információs mátrixba

$$E \left[ \frac{d}{d\theta} \ln \bar{f}_y(\theta; y^N) \right] \left[ \frac{d}{d\theta} \ln \bar{f}_y(\theta; y^N) \right]^T$$

Igy a várható érték:

$$\begin{aligned} M_N &= E \sum_{i=1}^N \sum_{j=1}^N \ell'_0(\varepsilon(i, \theta)) \ell'_0(\varepsilon(j, \theta)) \Psi(i, \theta_0) \Psi^T(j, \theta_0) \\ &= \sum_{i=1}^N E[\ell'_0(\varepsilon(i, \theta))]^2 E[\Psi(i, \theta_0) \Psi^T(i, \theta_0)] \quad , \quad \Psi(i, \theta_0) = - \frac{d}{d\theta} \varepsilon(i, \theta) \Big|_{\theta=\theta_0} \end{aligned}$$

figyelembe véve, hogy  $\varepsilon(i, \theta)$  független  $\varepsilon(j, \theta)$ -től  $i \neq j$ -re, mivel a predikciós hiba fehérzaj sorozatot alkot.

### 3. log-likelihood függvény $\ell'_0(x)$ deriváltja

---

$$\ell'_0(x) = [\ln f_\varepsilon(x)]' = \frac{f'_\varepsilon(x)}{f_\varepsilon(x)}$$

Ebből

$$E[\ell'_0(\varepsilon(i, \theta))]^2 = \frac{1}{\kappa_0}$$

ahol  $\kappa_0$  egy állandó.

Ha speciálisan a  $\varepsilon(i, \theta)$  hibák normális eloszlásúak  $\lambda_0$  szórásnégyzettel, akkor  $\kappa_0 = \lambda_0$ .

## 4. a Fisher információs mátrix egyszerű alakja

---

$$M_N = \frac{1}{\kappa_0} \sum_{i=1}^N E[\Psi(i, \theta_0) \Psi^T(i, \theta_0)]$$

A Cramér-Rao egyenlőtlenség segítségével kapjuk végül a dinamikus modellek paraméterbecslésének jóságára vonatkozó alapvető eredményt.



## A becsült paraméterek kovariancia mátrixa

*Dinamikus rendszerek  $\theta$  paramétereinek becslésére használt tetszőleges torzítatlan  $\hat{\theta}_N$  becslés ( $E\hat{\theta}_N = \theta_0$ , ahol  $\theta_0$  a valódi paraméter) kovariancia mátrixára az alábbi alsó korlát adható:*

$$\text{Cov } \hat{\theta}_N \geq \kappa_0 \left[ \sum_{i=1}^N E \{ \Psi(i, \theta_0) \Psi^T(i, \theta_0) \} \right]^{-1}$$
$$\Psi(i, \theta_0) = - \left. \frac{d}{d\theta} \varepsilon(i, \theta) \right|_{\theta=\theta_0}$$

Normális eloszlású hibák esetén  $\kappa_0 = \lambda_0$ .

*ARX RENDSZEREK PARAMÉTERBECSLÉSÉNEK  
KOVARIANCIA MÁTRIXA*

# A teljes valószínűségi modell

SISO esetben:

$$\begin{aligned} \mathbb{M}(\theta) : \quad \hat{y}(k | \theta) &= -a_1 y(k-1) \cdots - a_n y(k-n) + b_0 u(k) + \cdots + b_m u(k-m) \\ \varepsilon(k, \theta) &= y(k) - \hat{y}(k | \theta) \text{ függetlenek,} \\ &\text{adott } f_\varepsilon(x, \theta) \text{ sűrűségfüggvénnyel} \end{aligned}$$

## A likelihood függvény és a maximum likelihood becslés

$$\bar{f}_y(\theta; y^N) = \prod_{i=1}^N f_\varepsilon(\varepsilon(\theta, i), \theta) \quad , \quad \ell(\varepsilon, \theta, k) = -\ln f_\varepsilon(\varepsilon(\theta, k), \theta) = \ell(\varepsilon(\theta, k), \theta)$$

A paraméterek maximum likelihood becslése:

$$\hat{\theta}_{ML}(y^N) = \arg \min_{\theta} \frac{1}{N} \sum_{i=1}^N -\ell(\varepsilon(\theta, i), \theta)$$

# Normális eloszlású predikciós hiba esete 1

---

A predikciós hibák függetlenek és azonos normális eloszlásúak (SISO eset!):

$$f_{\varepsilon}(x, \theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}}$$

**A log-likelihood függvény:**

$$\begin{aligned} \ln \bar{f}_y(\theta; y^N) &= \sum_{k=1}^N \left[ -\ln \left( \frac{1}{\sigma\sqrt{2\pi}} \right) + \right. \\ &\left. + \ln \left( \exp \left( -\frac{(y(k) + a_1 y(k-1) + \dots + a_n y(k-n) - b_0 u(k) - \dots - b_m u(k-m))^2}{2\sigma^2} \right) \right) \right] \end{aligned}$$

## Normális eloszlású predikciós hiba esete 2

A **log-likelihood függvény** egyértelmű **minimuma** a paraméterek

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

szerinti derivált vektor nulla helye:

$$\frac{d}{d\theta} \ln \bar{f}_y(\theta, y^N) = \begin{bmatrix} \sum_{k=1}^N 2y(k-1) \frac{y(k) + a_1y(k-1) + \dots + a_ny(k-n) - b_0u(k) - \dots + b_mu(k-m)}{2\sigma^2} \\ \dots \\ \sum_{k=1}^N 2u(k) \frac{y(k) + a_1y(k-1) + \dots + a_ny(k-n) - b_0u(k) - \dots - b_mu(k-m)}{2\sigma^2} \\ \dots \end{bmatrix}$$

## Normális eloszlású predikciós hiba esete 3

A LKN módszernél megismert regresszorral

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

a **ML** becslés

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

Ekkor a **Fischer információs mátrix a bemenet és kimenet sztochasztikus folyamatok negyedrendű auto- és keresztkovarianciáit tartalmazza** (ld. egyszerű példa)