

*Dinamikus rendszerek paramétereinek becslése*  
*Nemlineáris dinamikus rendszerek paramétereinek*  
*becslése*

**Hangos Katalin**

PE Villamosmérnöki és Információs Rendszerek Tanszék

# *ISMÉTLÉS*

# 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*

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

# *FELADATKITÜZÉS*

# Nemlineáris rendszerek paraméterbecslési feladata

---

A nemlineáris és paraméterekben nemlineáris rendszerek paramétereinek becslése az általános paraméterbecslési optimalizálási feladat megoldását igényli.

A paraméterbecslési módszereket az egybemenetű-egykimenetű dinamikus rendszerek példáján mutatjuk be.

## A paraméterbecslés, mint nemlineáris optimalizálási feladat 1

---

### Adott:

1. Egy  $D^N = \{(y(k), u(k)) | k = 1, \dots, N\}$  **mért érték sorozat**;
2. **Prediktív modell: SISO eset**

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

(Speciális eset: paraméterekben lineáris

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

egy  $g^*(.)$  adott mért adatokban nemlineáris vektor értékű függvénnel);

3. Ebből és a mért kimenetekből számolható a **predikciós hiba sorozat**

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

4. Egy **veszteségfüggvény** alkalmas  $\ell(.)$  vektornormával

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

## A paraméterbecslés, mint nemlineáris optimalizálási feladat 2

---

### Keressük:

azt a paraméterbecslési módszert, amely a mért értékekből előállít egy  $\hat{\theta}_{\text{modsz}}(D^N)$  becslést úgy, hogy

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

**Speciális eset:** paraméterekben nemlineáris, de állandó paraméterű SISO rendszer paramétereit a **legkisebb négyzetes elvű** becsléssel becsüljük.

Veszteségfüggvény:

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

Optimalizálási feladat:

$$\hat{\theta}_{LKN}(D^N) = \arg \min_{\theta} \frac{1}{N} \sum_{k=1}^N \frac{1}{2} [y(k) - g(k, D^{k-1}; \theta)]^2$$

# Az optimalizálási feladat lehetséges megoldási útjai 1

Az adott  $D^N$  minta melletti **optimalizálási feladat** célfüggvénye ugyan látszólag kvadratikus, a nemlineáris  $g(k, D^{k-1}; \theta)$  függvény jelenléte miatt azonban **analitikusan általában nem megoldható**.

**több lokális minimum** is lehet

Analitikus megoldás hiányában az optimalizálási feladatot numerikus közelítő eljárásokkal oldhatjuk meg, az alábbi, elvileg különböző két módon.

## 1. **Nemlineáris egyenletrendszer megoldására vezető út**

Ez esetben az optimum szükséges feltételét jelentő

$$\frac{1}{N} \sum_{k=1}^N \frac{1}{2} [y(k) - g(k, D^{k-1}; \theta)] \frac{\partial g}{\partial \theta_j} = 0 \quad , \quad j = 1, \dots, N$$

nemlineáris egyenletrendszert kell megoldani numerikus módszerrel.

Probléma: **a megoldás általában nem egyértelmű**, és **a konvergencia** gyorsasága (és az, hogy melyik megoldáshoz konvergál) **erősen függ a kezdeti becsléstől**.



## Az optimalizálási feladat lehetséges megoldási útjai 2

---

### 2. **Direkt megoldás a $V_N(\theta, \mathbf{D}^N)$ veszteségfüggvény $\theta$ szerinti minimalizálásával**

Ez a feladat **numerikus függvényminimalizáló eljárásokkal**, például az úgynevezett gradiens módszerrel **oldható meg**.

Itt is **problémát jelent, hogy** úgynevezett **globális optimalizálási eljárásokra van (lenne) szükség a több lehetséges lokális minimum miatt**.

# *A GRADIENS MÓDSZER*

# A gradiens módszer elve 1

A gradiens módszer egy általános függvény szélsőérték (minimum vagy maximum) kereső eljárás, amely **lokális szélsőérték-keresésre alkalmas**.

Adott egy

$$G : \mathbb{R}^m \rightarrow \mathbb{R}$$

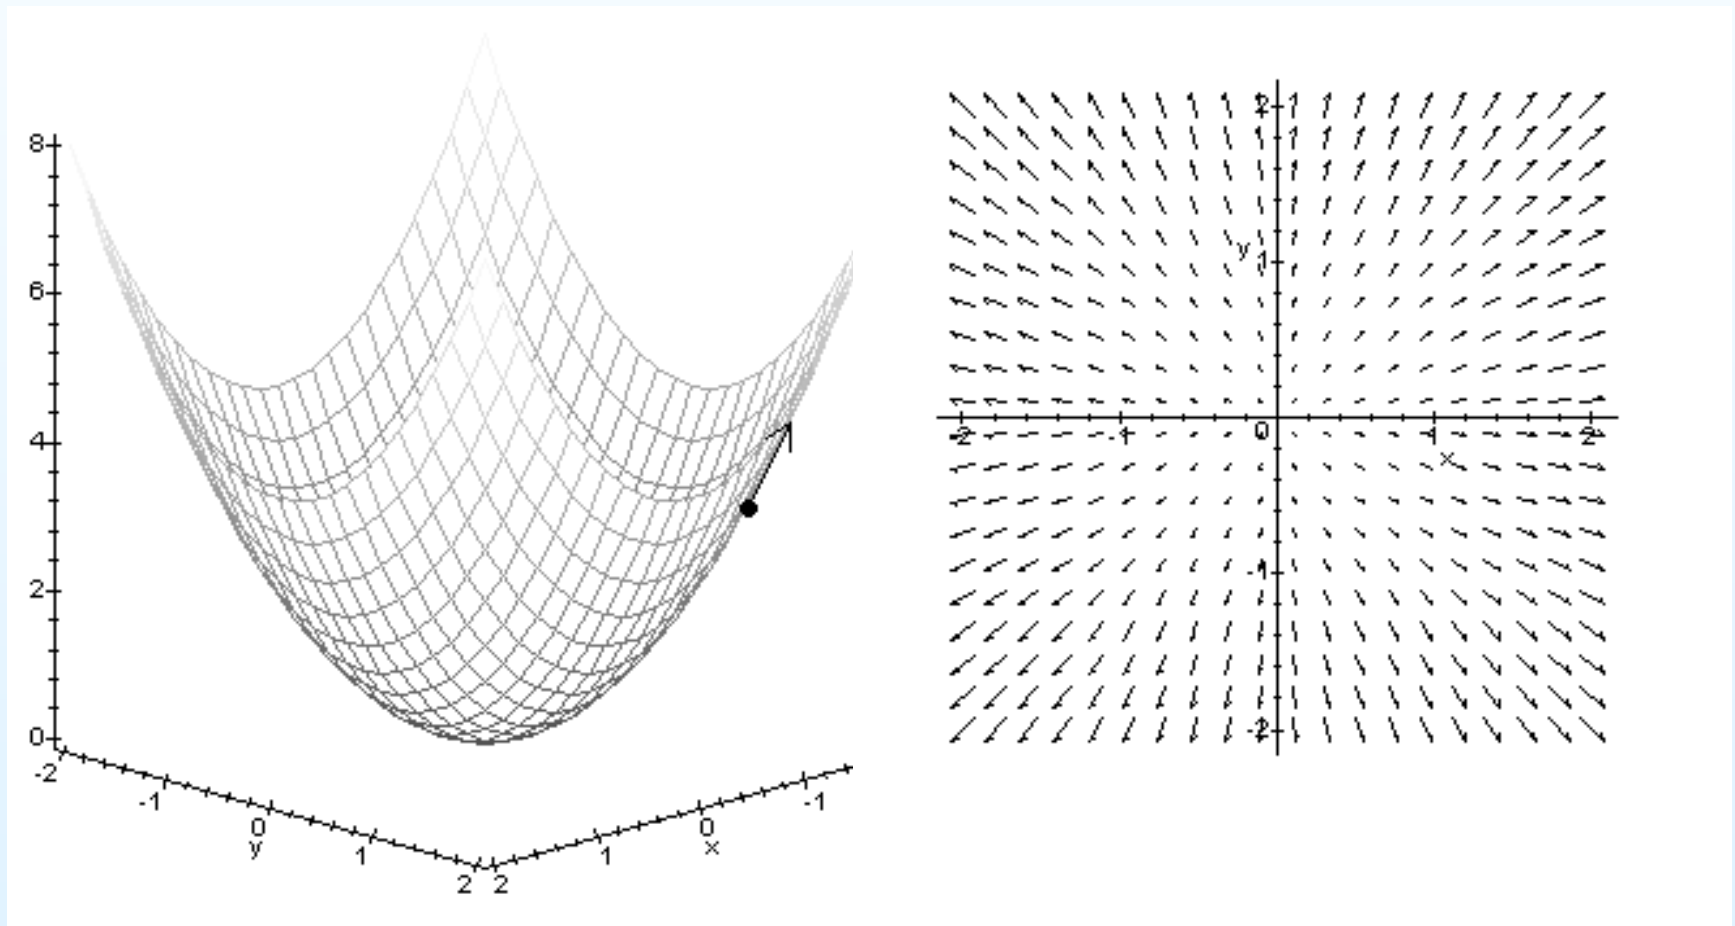
többszörös skalárértékű nemlineáris függvény. Ennek **gradiense** (gradiens vektora) **valamely  $\mathbf{x}^* \in \mathbb{R}^m$  pontban a**

$$\mathbf{G}_{\mathbf{X}}(\mathbf{x}^*) = \text{grad } G(\mathbf{x}^*) = \left[ \frac{\partial G}{\partial x_1}(\mathbf{x}^*) \dots \frac{\partial G}{\partial x_m}(\mathbf{x}^*) \right]^T \quad (1)$$

$m$ -dimenziós vektor, ahol  $x_i$  az  $x$  vektor  $i$ -edik koordinátája. **A gradiens vektor a  $G$  függvény, mint az  $(m + 1)$ -dimenziós  $\mathbb{R}^{m+1}$  térben értelmezett felület  $x^*$  pontjában húzott érintők közül a legmeredekebb irányába mutat.**

## A gradiens módszer elve 2

Az alábbi ábra egy álló forgási paraboloid felületet mutat. Meghúztuk a felület egy pontjában a gradiens vektort is, az ábra jobb oldali részében pedig a gradiens mező, azaz az egyes pontokban húzható gradiens vektorok vetületei láthatóak.



## A gradiens módszer elve 3

---

A  $G$  függvény görbületét, azaz konvex vagy konkáv voltát valamely  $x^* \in \mathbb{R}^m$  pontban a  $H_G = G_{XX}$  mátrix, az úgynevezett *Hesse mátrix* mutatja, amelynek  $ij$ -edik eleme

$$[G_{XX}]_{ij} = \frac{\partial^2 G}{\partial x_i \partial x_j}$$

**A  $G$  függvénynek minimuma** (lehet, hogy csak lokális minimuma) **van az  $x^*$  pontban, ha**

$$\text{grad } G(x^*) = \tilde{0} \quad \text{és} \quad G_{XX}(x^*) > 0$$

azaz  $G_{XX}(x^*)$  Hesse mátrix pozitív definit.

# A gradiens módszer

A gradiens módszer egy iteratív közelítő módszer egy többváltozós függvény szélsőértékének meghatározására. Használatához szükség van

- egy alkalmas  $x_0$  kezdőértékre,
- egy  $\varepsilon$  pontossági korlátra,
- egy  $\delta$  lépésközre.

Az algoritmus fő lépései minimumkeresés esetén a következők:

1. Legyen  $i := 0$ , ahol  $i$  az iterációs lépések száma és  $x_i = x_0$
2. Számítsuk ki a veszteségfüggvény  $x_i$  pontbeli  $\vec{G}_X(x_i)$  gradiensvektorát.
3. Ha a gradiensvektor már "elég kicsi", azaz  $\|\vec{G}_X(x_i)\| < \varepsilon$ , akkor elértük a minimumot, és  $x_{min} = x_i$ .
4. Egyébként lépünk egyet a negatív gradiens irányába, azaz

$$x_{i+1} = x_i - \vec{G}_X(x_i)\delta$$

megnöveljük a számlálót, azaz  $i := i + 1$ , majd a 2. lépéstől folytatjuk.

## A veszteségfüggvény minimalizálása gradiens módszerrel

---

A  $V_N(\theta, D^N)$  veszteségfüggvény  $\theta$  szerinti minimalizálására is használhatjuk a gradiens módszer algoritmusát az alábbi megfeleltetésekkel:

$$\begin{array}{rcl} V_N(\theta, D^N) & \sim & \mathbf{G}(\mathbf{x}) \\ \theta & \sim & \mathbf{x} \end{array}$$

A szükséges **induló (a priori) adatok**:

- egy alkalmas  $\theta_0$  **kezdő paramétervektor érték**,
- egy  $\varepsilon$  **pontossági korlát**,
- egy  $\delta$  **lépésköz a paraméterek terében**.

Fontos megjegyezni, hogy **a gradiens módszer**

- **lokális szélsőérték kereső módszer**, azaz a **becsült paraméterérték függhet a kezdeti érték jó**, azaz a valódi érték közeli **megválasztásától**,
- egy iterációs lépés **polinomiális időbonyolultságú**, és a **gyakorlati algoritmusok gondoskodnak a  $\delta$  lépésköz megfelelő változtatásáról**, azaz a **minimum közelében megfelelő csökkentéséről**.

# *NEMLINEÁRIS MODELLEK MUNKAPONT KÖRÜLI LINEARIZÁLÁSA*



## Linearizálás: centrált változók

---

**A nemlineáris modellek paramétereinek becslését gyakran munkapont körül linearizált változatuk segítségével végezzük, hiszen a lineáris, de legalábbis paraméterekben lineáris modellek becslésére számos hatékony és aszimptotikusan torzítatlan módszer áll rendelkezésre.**

Irányítási feladatoknál, így dinamikus rendszerek paramétereinek becslésénél is általában  $\tilde{x}$  **munkapont körüli**, azaz úgynevezett **perturbációs változókkal dolgozunk, amelyeket valamely  $x_0$  referencia pont vagy állandósult állapottól való eltérésükkel definiálunk:**

$$\tilde{x} = x - x_0$$

ahol  $x_0$  az  $x$  változó állandósult állapotbeli értéke.

# Munkapont körüli linearizálás 1

**A linearizálás a linearizálandó nemlineáris függvény állandósult állapot körüli Taylor sorfejtésén alapszik.** Egy egyváltozós dinamikus nemlineáris  $y = f(x, t)$  függvénynél az  $x$  változó szerinti Taylor sorfejtés az alábbi alakban írható:

$$f(x, t) = f(x_0, t) + \left. \frac{df}{dx} \right|_{x_0} (x - x_0) + \left. \frac{d^2 f}{dx^2} \right|_{x_0} \frac{(x - x_0)^2}{2!} + \dots \quad (2)$$

ahol  $x_0$  a referencia pont és  $\left. \frac{d^i f}{dx^i} \right|_{x_0}$  az  $f$  függvény  $x$  szerinti  $i$ -edik parciális deriváltja, amelyet az  $x_0$  referencia pontban veszünk.

A fenti sorfejtés első két tagja utáni magasabbrendű tagok elhanyagolásával kapjuk a lineáris közelítést:

$$f(x, t) \simeq f(x_0, t) + \left. \frac{df}{dx} \right|_{x_0} (x - x_0)$$

és így az eredeti nemlineáris egyenlet az

$$y = f(x_0, t) + \left. \frac{df}{dx} \right|_{x_0} (x - x_0)$$

formulával közelíthető.

# Függvények linearizálása

A  $y = f(x_0, t) + \left. \frac{df}{dx} \right|_{x_0} (x - x_0)$  közelítő alakból a  $\tilde{y} = y - y_0 = y - f(x_0, t)$ -t helyettesítve

$$\tilde{y} = \left. \frac{df}{dx} \right|_{x_0} \cdot \tilde{x}$$

amely a végső linearizált egyenlet az  $\tilde{x}$  perturbációs változóval kifejezve.

**Többváltozós skalárértékű  $f(x_1, \dots, x_n, t)$  esetre:**

$$\tilde{y} = \mathbf{J}|_{\mathbf{x}_0} \cdot \tilde{\mathbf{x}}$$

**ahol  $\mathbf{J}$  a függvény úgynevezett Jacobi mátrixa** (ez esetben sorvektor), amelynek  $i$ -edik eleme a megfelelő  $x_i$  változó szerinti parciális derivált, azaz

$$J_i = \frac{\partial f}{\partial x_i}$$

## Nemlineáris prediktor linearizálása

A fenti elvet alkalmazzuk az alábbi nemlineáris prediktor linearizálására:

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

Először definiálunk (keresünk) egy alkalmas  $x_*$  munkapontot:

$$x_* = (y_*, u_*, \theta_*)$$

$$D_*^N = \{y(k) = y_*, u(k) = u_* | k = 1, \dots, N\}$$

Ezek után alkalmazzuk a **többszörös lineáris Taylor közelítést**

$$\tilde{\hat{y}}(\mathbf{k}|\theta) = \sum_{\mathbf{i}=1}^{\mathbf{k}} \left[ \frac{\partial \mathbf{g}}{\partial \mathbf{u}(\mathbf{i})} \Big|_{\mathbf{x}_*} \tilde{\mathbf{u}}(\mathbf{i}) + \frac{\partial \mathbf{g}}{\partial \mathbf{y}(\mathbf{i})} \Big|_{\mathbf{x}_*} \tilde{\mathbf{y}}(\mathbf{i}) \right]$$

felhasználva azt, hogy a  $\theta$  paraméterek nem változnak, azaz  $\tilde{\theta} = 0$ .