



10. előadás

Kiegyenlítő számítások MSc

2018/19

Áttekintés

- Paraméterbecslések

Valószínűségeloszlások paramétereinek
maximum likelihood becslése

Maximum likelihood típusú becslések (M-
becslések)

Paraméterbecslés

- Statisztikai minta eloszlásfüggvénye, ismeretlen paraméterek, sűrűségfüggvény
- Likelihood függvény
- Torzítatlan, hatékony, konzisztens becslés
- A maximális valószínűség (maximum likelihood) módszere
- M-becslések

Statisztikai becslés

- Azt a statisztikai eljárást, mely a minta ismeretében valamely mintajellemzőt állít elő, *statisztikai becslésnek* nevezzük
- Először tegyük fel, hogy ismerjük az adateloszlást jellemző $f(x)$ sűrűségfüggvény típusát
maximum likelihood (ML) becslés
- Ha nem ismerjük az $f(x)$ sűrűségfüggvény típusát
M-becslés

Statisztikai minta eloszlásfüggvénye

- Statisztikai *minta* mért értékek (valószínűségi változók) együttese: $\xi_1, \xi_2, \dots, \xi_n$
- Minta *eloszlásfüggvényei*: $F_1(x), F_2(x), \dots, F_n(x)$
- Minta *együttes* eloszlásfüggvénye

független mintavétel:

$$F(x_1, x_2, \dots, x_n) = \prod_{i=1}^n F_i(x_i)$$

azonos eloszlású mintaelemek: $F(x_1, x_2, \dots, x_n) = \prod_{i=1}^n F(x_i)$

ismeretlen *paraméterek* (a_1, a_1, \dots, a_m)

$$F(\mathbf{x}, \mathbf{a}) = F(x_1, x_2, \dots, x_n; a_1, a_2, \dots, a_m)$$

Minta sűrűségfüggvénye, likelihood függvény

- Statisztikai minta *sűrűségfüggvénye* az x_1, x_2, \dots, x_n változók szerinti derivált

$$L(\mathbf{x}, \mathbf{a}) = L(x_1, x_2, \dots, x_n; a_1, a_2, \dots, a_m) = \frac{\partial^n F(\mathbf{x}, \mathbf{a})}{\partial x_1 \partial x_2 \dots \partial x_n}$$

- Ez a *likelihood függvény*
- logaritmususa a *loglikelihood függvény*

Paraméterbecslés kívánatos tulajdonságai

- Statisztikai minta bármely függvénye a *statisztika*

$$\tilde{a}_k = t_k(\xi_1, \xi_2, \dots, \xi_n) = t_k(\xi)$$

- *Torzítatlan* becslés

$$M(\tilde{a}_k) = a_k \quad k = 1, 2, \dots, m$$

- A becsült paraméter szórása legyen a lehető legkisebb

Nem csökkenthető minden határon túl (*Cramér-Rao határ*)

Érje el ezt az alsó határt, vagyis legyen *hatékony* (*efficiens*) becslés

Paraméterbecslés kívánatos tulajdonságai

- A becslés legyen *konzisztens*

Egy becslési eljárás *konzisztens*, ha a mérések n számának növekedésével a paraméterek becsült értékei a valódi értékhez tartanak

$$\lim_{n \rightarrow \infty} P \left\{ |\tilde{a}_k - a_k| > \varepsilon \right\} = 0$$

minden k -ra és tetszőleges pozitív ε -ra

- Gyakori eset, hogy a paraméterek becsült értékeinek a szórása növekvő n -el 0-hoz tart:

$$\lim_{n \rightarrow \infty} D(\tilde{a}_k) = 0, \quad k = 1, 2, \dots, m$$

Ekkor a becslés konzisztens

Maximum likelihood módszer

- Elv: Keressük azt az a paraméteret, amelyre a minta $p(\mathbf{x}, a)$ valószínűsége maximális lesz

ismernünk kell a minta eloszlását

- Fisher vezette be ezen a néven a módszert 1912-ben
- A maximum likelihood elv konzisztens becslésekhez vezet, mely elég nagy n -re közelítőleg Gauss eloszlású
- Példa


Cauchy eloszlású mintánk van, egységnyi skála paraméterrel ($S = 1$)

T helyparamétert becsüljük

Maximum likelihood módszer

- $f(x)$ típusát ismerjük:
Cauchy eloszlás ($f_C(x)$)
- 10 elemű mintánk van
[12.3, 16.6, 17.6, 18.1, 18.4,
18.8, 19.1, 19.6, 20.6, 24.9]
- A T helyparaméter maximum likelihood becslését keressük

$$\prod_{i=1}^{10} f_C(x_i, T) = \text{maximum}$$




Maximum likelihood módszer

- szemilogaritmikus skálán

$$\prod_{i=1}^{10} f_C(x_i, T)$$

- A T helyparaméter maximum likelihood becslése: 18.6



ML becslés algoritmus

- Milyen algoritmus alkalmazásával számíthatjuk ki a maximum likelihood (ML) elvnek eleget tevő T értéket?

attól függ, milyen az a priori ismert $f(x)$ analitikus alakja:

$$p(\mathbf{x}, T) = \prod_{i=1}^n f(x_i, T) \cdot (\Delta x)^n = \text{maximum}$$

ezzel ekvivalens alakok

$$\prod_{i=1}^n f(x_i, T) = \text{maximum}$$

$$\sum_{i=1}^n \ln f(x_i, T) = \text{maximum}$$

ML becslés – Cauchy eloszlás

- Az ismert eloszlásfüggvény Cauchy-féle ($f_C(x)$)

$$f(x) = f_C(x) = \frac{1}{\pi} \frac{1}{1 + (x - T)^2}$$

- a ML becslés $\sum_{i=1}^n \ln \frac{1}{1 + (x_i - T)^2} = \text{maximum}$

- differenciálás után $\sum_{i=1}^n \frac{x_i - T}{1 + (x_i - T)^2} = 0$

- megoldás T -re:
$$T = \frac{\sum_{i=1}^n \frac{x_i}{1 + (x_i - T)^2}}{\sum_{i=1}^n \frac{1}{1 + (x_i - T)^2}}$$

ML becslés – Cauchy eloszlás

- Az egységnyi helyett ε szélesség paraméterű eloszlásra

$$T = \frac{\sum_{i=1}^n \frac{x_i}{\varepsilon^2 + (x_i - T)^2}}{\sum_{i=1}^n \frac{1}{\varepsilon^2 + (x_i - T)^2}} = M_n = \frac{\sum_{i=1}^n \frac{x_i}{\varepsilon^2 + (x_i - M_n)^2}}{\sum_{i=1}^n \frac{1}{\varepsilon^2 + (x_i - M_n)^2}}$$

A ML becslés algoritmus a *leggyakoribb érték* meghatározásának algoritmusával

ML becslés – Gauss eloszlás

- Az ismert eloszlásfüggvény Gauss-féle ($f_G(x)$)

$$f(x) = f_G(x) = \text{const} \cdot e^{-\frac{(x-T)^2}{2}}$$

a ML becslés $-\sum_{i=1}^n (x_i - T)^2 = \text{maximum}$

differenciálás után $\sum_{i=1}^n (x_i - T) = 0$

megoldás T -re: $T = \frac{1}{n} \sum_{i=1}^n x_i$

ML becslés – Gauss eloszlás

- Az egységnyi szélesség paraméterű eloszlásra

$$T = \frac{1}{n} \sum_{i=1}^n x_i = E_n$$

A ML becslés algoritmus a *számtani átlag* meghatározásának algoritmusával

- C. F. Gauss fordított gondolatmenete:

Melyik az a sűrűségfüggvény, amelyhez optimális szimmetriapont meghatározási algoritmusként a számtani átlagképzés tartozik?

A válasz: a *Gauss eloszlás* („normális” eloszlás) sűrűségfüggvénye

Gauss eloszlás S skála paraméterének ML becslése

- likelihood függvény

$$L = \prod_{i=1}^n f(x_i, S, T) = \prod_{i=1}^n \frac{1}{S \sqrt{2\pi}} e^{-\frac{1}{2S^2} \cdot (x_i - T)^2} = \frac{1}{(S \sqrt{2\pi})^n} e^{-\frac{1}{2S^2} \sum_{i=1}^n (x_i - T)^2}$$

- loglikelihood függvény

$$L^* = \ln L = \left(-n \ln S - \frac{n}{2} \ln 2\pi \right) - \left(\frac{1}{2S^2} \sum_{i=1}^n (x_i - T)^2 \right) = \max$$

- S szerinti parciális derivált

$$\frac{\partial L^*}{\partial S} = -\frac{n}{S} + \frac{1}{S^3} \sum_{i=1}^n (x_i - T)^2 = 0$$

- S skála paraméter ML becslése az empirikus szórás

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - T)^2} = \sigma_n$$

ML becslés és M-becslés

- Az ML becslés *minimumfeltételként* megfogalmazva:

$$-\sum_{i=1}^n \ln f(x_i, T) = \text{minimum}$$

A gyakorlatban sokszor nem ismerjük az anyaeloszlás, $f(x)$ típusát

- *Huber* javaslata: helyettesítsük az ismeretlen negatív logaritmizált $f(x)$ eloszlást egy *ismert* $\rho(x)$ függvénnyel

$$\sum_{i=1}^n \rho(x_i, T) = \text{minimum}$$

ekkor is kapunk becslést a T helyparaméterre

ez az **M-becslés**

$\rho(x, T)$ a *célfüggvény*

M-becslés hatásfüggvénye

- A célfüggvény minimalizálása helyett a differenciálással kapható

$$\sum_{i=1}^n \psi(x_i, T) = 0$$

megoldása célszerűbb

- Az M-becslést a célfüggvény helyett közvetlenül a $\psi(\mathbf{x}, T)$ függvénnyel, a *hatásfüggvénnyel* is megadhatjuk:

$$\psi(\mathbf{x}, T) = \frac{\partial \rho(\mathbf{x}, T)}{\partial T}$$

a T helyparaméter becslés esetén

$$\sum_{i=1}^n \rho(x_i - T) = \text{minimum}$$

$$\sum_{i=1}^n \psi(x_i - T) = 0$$

M-becslés súlyfüggvénye

- a T helyparaméter becslés esetén, ha bevezetjük a

$$\varphi(x_i) = \frac{\psi(x_i - T)}{x_i - T}$$

súlyfüggvényt,

az M-becslést súlyozott átlag képzésére vezethetjük vissza:

$$\sum_{i=1}^n \varphi(x_i) \cdot (x_i - T) = 0$$

a megoldása

$$T = \frac{\sum_{i=1}^n \varphi(x_i) \cdot x_i}{\sum_{i=1}^n \varphi(x_i)}$$

M-becslés skálaparaméterre

- az S skálaparaméter becslés esetén a ψ -vel analóg függvényt χ -vel szokás jelölni
- az M-becslést az alábbi egyenlet megoldása adja:

$$\sum_{i=1}^n \chi\left(\frac{x_i - T}{S}\right) = 0$$

feltételezve, hogy a T helyparaméter már ismert

M-becslés az ismertebb eloszlástípusokra

1. Gauss eloszlás

$$f(x) = e^{-\frac{x^2}{2}}$$

$$\rho(x) = \frac{x^2}{2}$$

célfüggvény

$$\psi(x) = x$$

hatásfüggvény

$$\varphi(x) = 1$$

súlyfüggvény

az M-becslés az *átlaggal* egyezik meg

a hibák négyzetösszegét minimalizáljuk (ez a LKN vagy L2 norma szerinti becslés)

a hatásfüggvény *lineáris*, ezért

a megoldandó egyenletrendszer is *lineáris*

M-becslés az ismertebb eloszlástípusokra

2. Laplace eloszlás

$$f(x) = e^{-|x|} \quad \rho(x) = |x| \quad \psi(x) = \text{sign } x \quad \varphi(x) = \frac{1}{|x|}$$

célfüggvény hatásfüggvény súlyfüggvény

az M-becslés a *mediánnal* egyezik meg

ahhoz, hogy az előjelek összege zérus legyen, az adatok felének előjele pozitív, a másik feléé negatív kell, hogy legyen – ez a tapasztalati medián (sign y : y előjele: +1/-1)

a hibák abszolút értékének összegét minimalizáljuk (L1 norma szerinti becslés, Boscovich, 1790, Laplace, 1799)

M-becslés az ismertebb eloszlástípusokra


3. Cauchy eloszlás

$$f(x) = \frac{1}{1+x^2} \quad \rho(x) = \ln(1+x^2) \quad \psi(x) = \frac{2x}{1+x^2} \quad \varphi(x) = \frac{2}{1+x^2}$$

célfüggvény hatásfüggvény súlyfüggvény

az M-becslés a *leggyakoribb* értékkel egyezik meg (Steiner, 1990)
csak iterációval határozható meg

Az M-becslők hatásfüggvényei



- Ha a hatásfüggvény nem korlátos, a becslés nem rezisztens (vagyis érzékeny a kivágó értékekre):

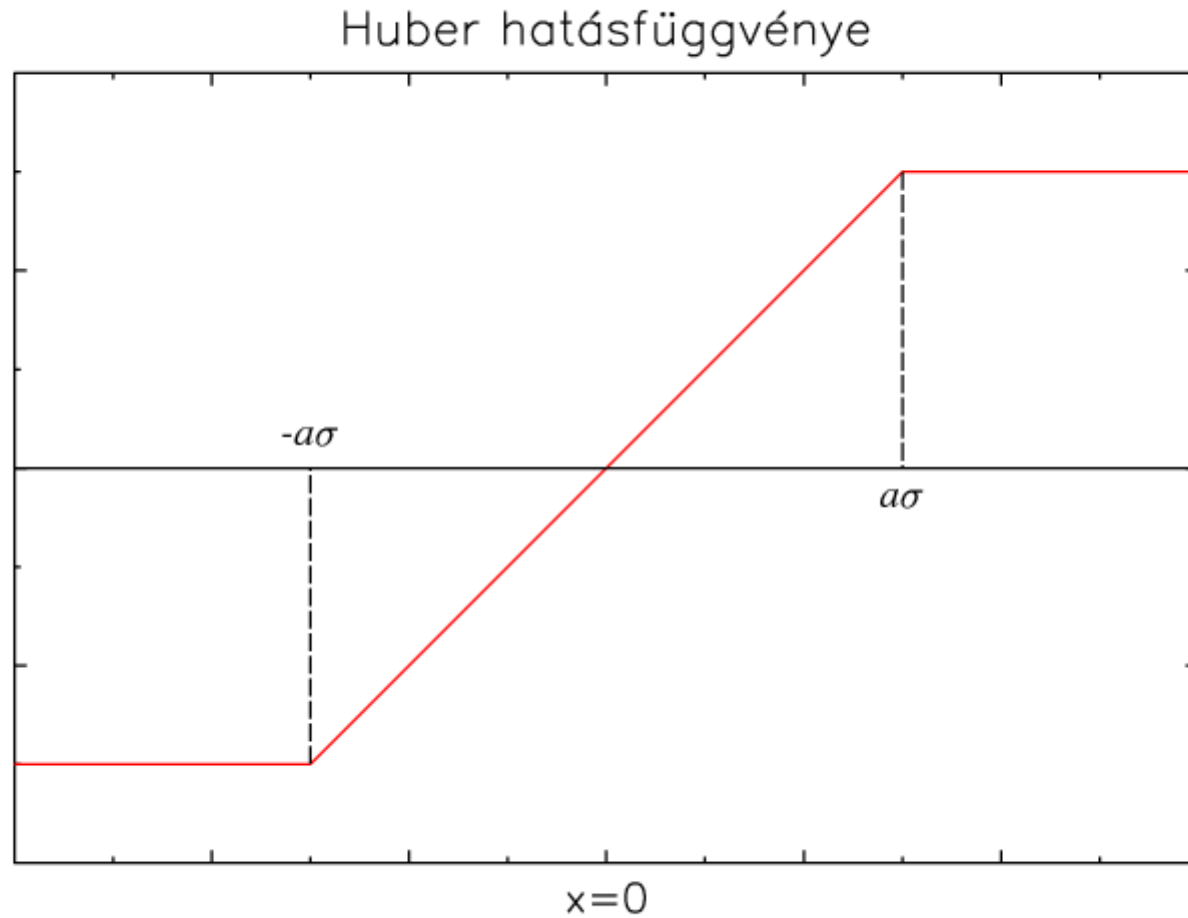
A Gauss eloszláson alapuló M-becslés nem rezisztens

Huber hatásfüggvénye

- A tapasztalatok szerint a geodéziai mérési eredmények hibaeloszlása középen gyakran jó közelítéssel Gauss eloszlású, de a széleken bizonytalan
- Huber az alábbi hatásfüggvényt javasolta (például az $a = 1.5\sigma$ paraméterrel)

$$\Psi(x) = \begin{cases} x, & \text{ha } |x| \leq a \\ a \operatorname{sign} x & \text{egyébként} \end{cases}$$

A Huber hatásfüggvény alakja

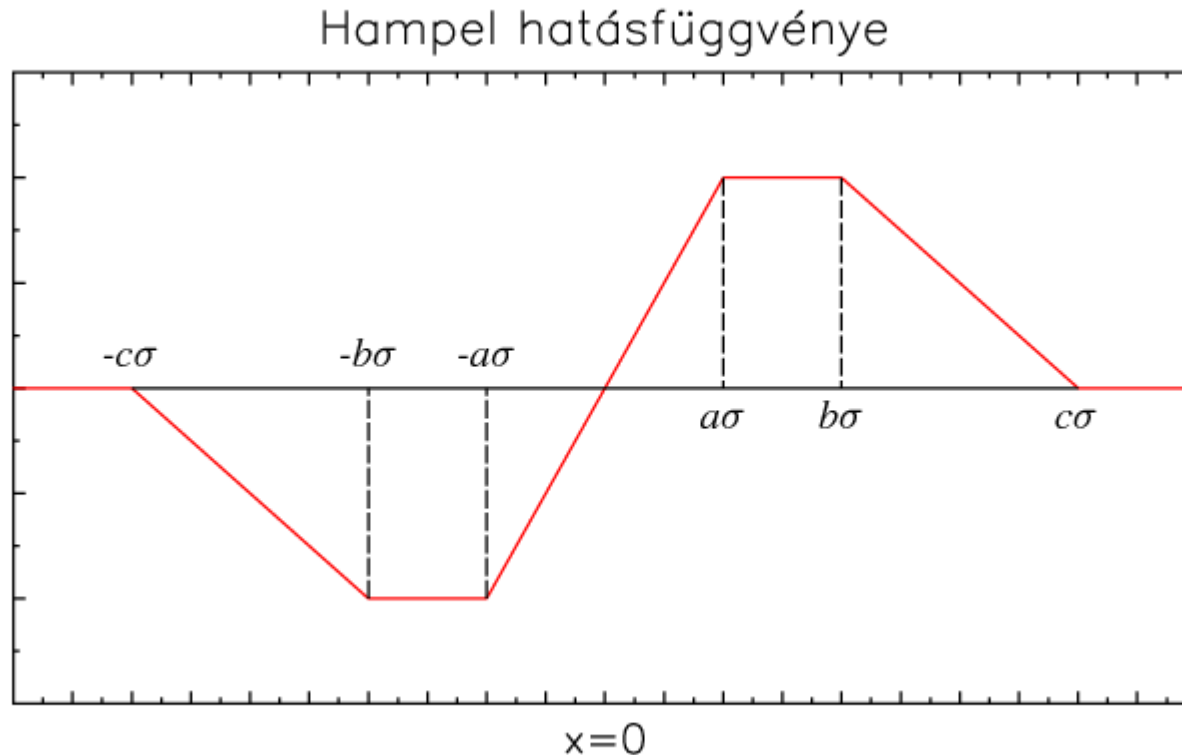


Hampel hatásfüggvénye

- A durva hibák (kivágó értékek) biztos kizárása érdekében Hampel a hatásfüggvényt a széleken csökkentette

$$\Psi(x) = \begin{cases} x, & \text{ha } |x| \leq a \\ a \operatorname{sign} x & \text{ha } a < |x| \leq b \\ \frac{a(c \operatorname{sign} x - x)}{c - b} & \text{ha } b < |x| \leq c \\ 0 & \text{egyébként} \end{cases}$$

A Hampel hatásfüggvény alakja



$x > 0$ értékekre 4 részből áll a hatásfüggvény
pl. a dán geodéziai alaphálózat kiegyenlítésekor
alkalmazták

Rezisztens kiegyenlítés M-becslőkkel

- *Hampel* hatásfüggvényét alkalmazzuk a közvetett mérések rezisztens kiegyenlítésére

Huber hatásfüggvénye *Hampel* speciális esete,
ha $b = c = \infty$

- r elemű \mathbf{x} paramétervektor
- n elemű \mathbf{v} hibavektor

$$\mathbf{v} = \mathbf{A} \mathbf{x} - \mathbf{l} \quad \mathbf{A} = \left[a_{i,j} \right]_{\substack{j=1,r \\ i=1,n}}$$

A célfüggvény minimalizálása

- az \mathbf{x} paramétervektor legjobb becslésének feltételi egyenlete:

$$\sum_{i=1}^n \rho(v_i, \mathbf{x}) \Rightarrow \min$$

- az aktuális szélsőérték-feladatnál:

$$v_i = \sum_{j=1}^r a_{i,j} x_j - l_i \quad i = 1, \dots, n$$

ezért

$$\frac{dv_i}{dx_k} = a_{i,k} \quad k = 1, \dots, r$$

A szélsőérték megkeresése

- az \mathbf{x} paramétervektor legjobb becslése a célfüggvény \mathbf{x} szerinti deriválásával:

$$\frac{d}{dx_k} \sum_{i=1}^n \rho(v_i(\mathbf{x})) = \sum_{i=1}^n \frac{d\rho(v_i(\mathbf{x}))}{dv_i} \frac{dv_i}{dx_k} = \sum_{i=1}^n a_{i,k} \psi(v_i) = 0 \quad k=1, \dots, r$$

tömörített írásmódban

$$\mathbf{A}^T \boldsymbol{\psi}(\mathbf{v}) = \mathbf{0} \quad \boldsymbol{\psi}(\mathbf{v}) = \begin{bmatrix} \psi(v_1) \\ \psi(v_2) \\ \vdots \end{bmatrix}$$

és $\boldsymbol{\psi}(\mathbf{v})$ a Hampel-féle hatásfüggvény

A mérési javítások Gauss eloszlásúak

- $\psi(\mathbf{v}) = \mathbf{v}$ (a hatásfüggvény lineáris)
- az \mathbf{x} paramétervektor „rezisztens” becslése megegyezik a LKN kiegyenlítéssel:

$$\mathbf{A}^T \mathbf{v} = \mathbf{A}^T (\mathbf{A}\mathbf{x} - \mathbf{l}) = 0$$

ebből

$$\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{l}$$

A Hampel-módszer javítási egyenletei

- az A mátrixot a v_i hibák nagysága alapján függőlegesen 4 almátrixra bonthatjuk

$$A_1 (|v_i| \leq a), A_2 (a < |v_i| \leq b),$$

$$A_3 (b < |v_i| \leq c) \text{ és } A_4 (c < |v_i|)$$

- particionáljuk ennek megfelelően a javítási egyenleteket:

$$\begin{bmatrix} v^1 \\ v^2 \\ v^3 \\ v^4 \end{bmatrix} = \begin{bmatrix} A_1 \\ A_2 \\ A_3 \\ A_4 \end{bmatrix} \cdot x - \begin{bmatrix} l_1 \\ l_2 \\ l_3 \\ l_4 \end{bmatrix}$$

A Hampel-módszer feltételi egyenletei

- a feltételi egyenleteket is 4 almatrixra bonthatjuk

$$\begin{bmatrix} \mathbf{A}_1^T & \mathbf{A}_2^T & \mathbf{A}_3^T & \mathbf{A}_4^T \end{bmatrix} \cdot \begin{bmatrix} \psi(\mathbf{v}^1) \\ \psi(\mathbf{v}^2) \\ \psi(\mathbf{v}^3) \\ \psi(\mathbf{v}^4) \end{bmatrix} = 0$$

amelyből

$$\mathbf{A}_1^T \psi(\mathbf{v}^1) + \mathbf{A}_2^T \psi(\mathbf{v}^2) + \mathbf{A}_3^T \psi(\mathbf{v}^3) + \mathbf{A}_4^T \psi(\mathbf{v}^4) = 0$$

A megoldandó egyenletrendszer

- A $\psi(\mathbf{v})$ a Hampel-féle hatásfüggvény behelyettesítése után

$$\mathbf{A}_1^T \mathbf{v}^1 + \mathbf{A}_2^T a \operatorname{sign} \mathbf{v}^2 + \mathbf{A}_3^T \frac{a}{c-b} (c \operatorname{sign} \mathbf{v}^3 - \mathbf{v}^3) = 0$$

a javításokat beírva

$$\mathbf{A}_1^T (\mathbf{A}_1 \mathbf{x} - \mathbf{l}_1) + \mathbf{A}_2^T a \operatorname{sign} \mathbf{v}^2 + \mathbf{A}_3^T \frac{a}{c-b} (c \operatorname{sign} \mathbf{v}^3 + \mathbf{l}_3 - \mathbf{A}_3 \mathbf{x}) = 0$$

A megoldandó egyenletrendszer

- Az előző egyenletet rendezve

$$\left[\begin{array}{c} \mathbf{A}_1^T \\ \mathbf{A}_1 - \mathbf{A}_3^T \mathbf{A}_3 \frac{a}{c-b} \end{array} \right] \mathbf{x} = \mathbf{A}_1^T \mathbf{l}_1 - \mathbf{A}_2^T a \operatorname{sign} \mathbf{v}^2 + \mathbf{A}_3^T \frac{a}{c-b} (c \operatorname{sign} \mathbf{v}^3 + \mathbf{l}_3)$$

- Végeredményben egy $\mathbf{B}\mathbf{x} = \mathbf{d}$ alakú egyenletrendszerhez jutunk, ahol

$$\mathbf{B} = \mathbf{A}^T \mathbf{P} \mathbf{A} \qquad \mathbf{d} = \mathbf{A}^T \mathbf{P} \mathbf{l} - a \mathbf{A}^T \mathbf{Q} \operatorname{sign} \mathbf{v}$$

A súlymátrixok

- az előző egyenletekben P és Q átlós súlymátrixok, melyeknek főátlóelemei:

$$p_{i,j} = \begin{cases} 1 & \text{ha } |v_i| \leq a \\ \frac{a}{b-c} & \text{ha } b < |v_i| \leq c \\ 0 & \text{egyébként} \end{cases} \quad q_{i,j} = \begin{cases} 1 & \text{ha } a < |v_i| \leq b \\ \frac{b}{c-b} & \text{ha } b < |v_i| \leq c \\ 0 & \text{egyébként} \end{cases}$$

- a megoldás *iteráció*ban történik
- a v ellentmondás-vektor alapján a kiegyenlítést mindig az aktuális *osztályba sorolás*nak megfelelően ismételjük meg

A dán módszer

- durvahibasűrésre kifejlesztett eljárás *Krarrup* (1967) elgondolása nyomán
- a mérések *iteratív újrásúlyozása* a kiegyenlítésből kapott mérési javítások függvényében (a gyakorlatban $a = 3$)

$$p_{i+1} = \begin{cases} 1 & \text{ha } |v_i| < a \cdot \sigma \\ e^{-\frac{|v_i|}{a \cdot \sigma}} & \text{egyébként} \end{cases}$$

Példa rezisztens M-kiegyenlítésre: regressziós egyenes számítása

- LKN paraméter becslés:

egyenes egyenlete:

$$y = ax + b$$

paraméter vektor:

$$\mathbf{x} = [a \quad b]^T$$

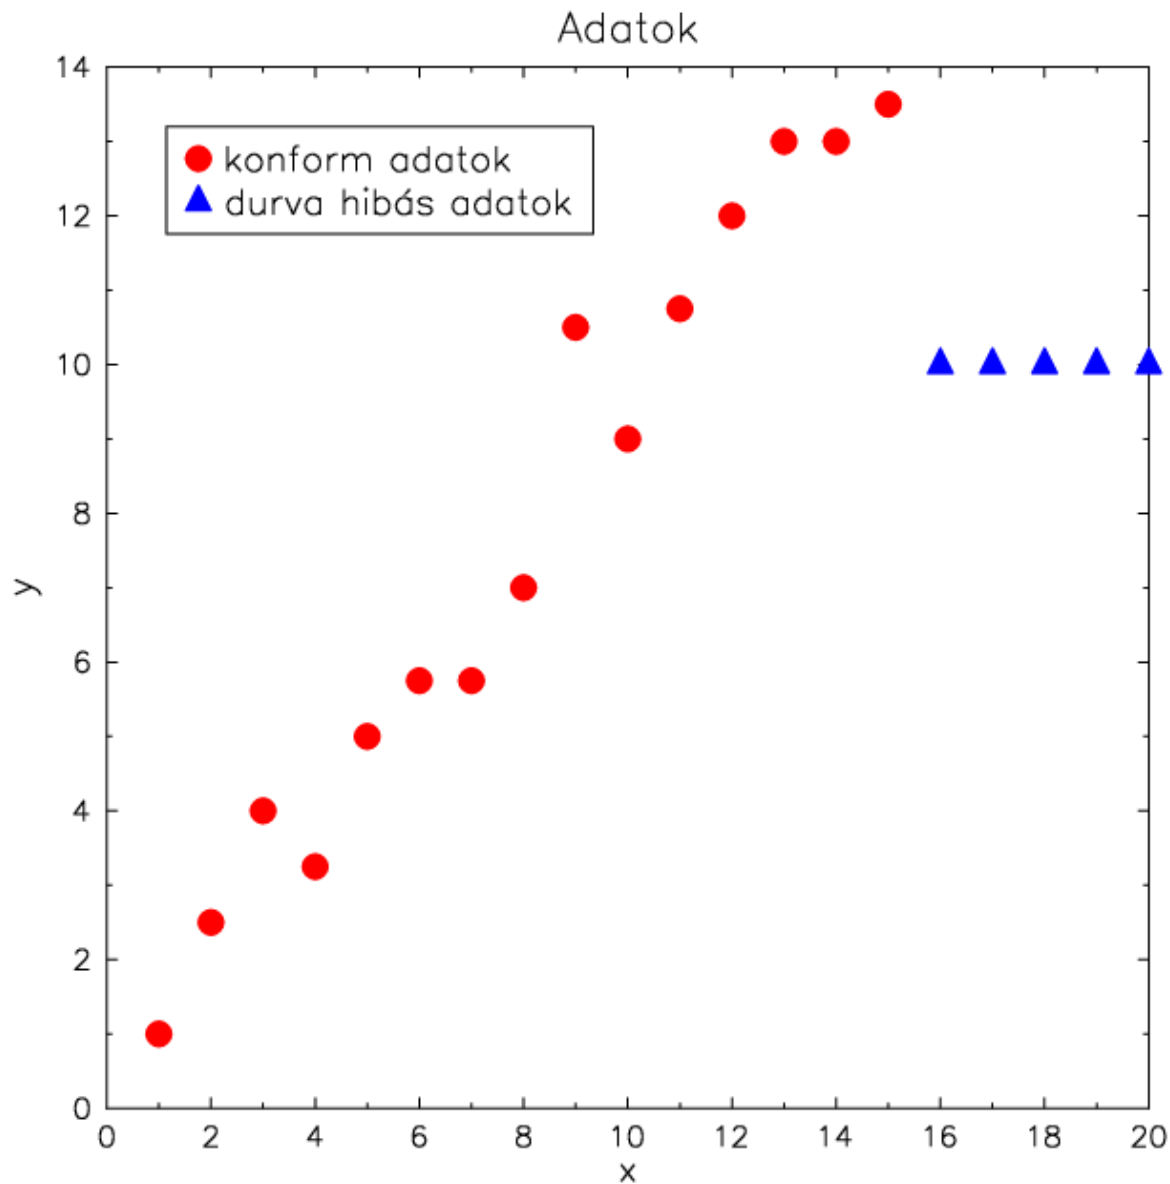
alakmátrix:

$$\mathbf{A} = \begin{bmatrix} x_1 & \cdots & x_n \\ 1 & \cdots & 1 \end{bmatrix}^T$$

tisztatag vektor:

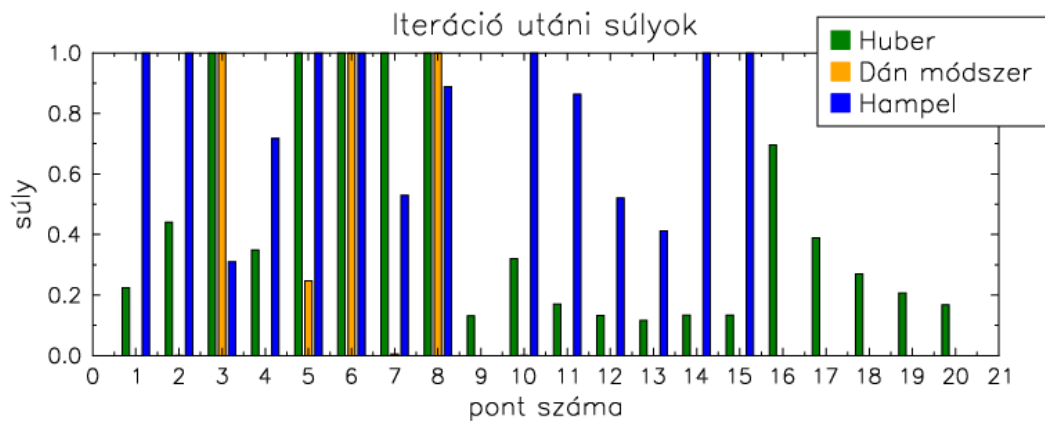

$$\mathbf{l} = [y_1 \quad \cdots \quad y_n]^T$$

Mérések (5/20 durva hibás)



Eredmények

Regressziós egyenesek



Tananyag, szakirodalom

- Steiner (1990): 5.2
- Vincze (1968): 4.2-4.4, 4.7.1
- Szabó Norbert Péter (2012): Bevezetés a geostatisztikába. Jegyzet. Miskolci Egyetem
- Huber P.J. (1981): Robust Statistics. Wiley & Sons
3.2 (M-Estimates)