



# 11. előadás



# Miről lesz szó?

- Robusztus és rezisztens mérés feldolgozás

Bevezetés

Robusztus és rezisztens becslések

Nagy számok törvényének teljesülése

Korreláció és regresszió

# Robusztus statisztika

- „A robusztus statisztika olyan elméleti keret, amelyen belül *gazdaságosan* oldható meg az a feladat, hogy egymástól jelentősen *eltérő eloszlástípusok* esetén is megbízható eredményt érjünk el, valamint hogy ne legyünk kitéve a *durva hibájú adatok* torzító (esetleg katasztrofális mértékben torzító) hatásának.” (Steiner, 1990)



# Miért fontos a robusztus mérésfeldolgozás?


- A legtöbb feltevés csak közelíti a valóságot, mert az adatok nem Gauss eloszlásúak  
a modellek nem lineárisak  
a mérések nem függetlenek
- Durva hibák is jelentkeznek, és tönkreteszhetik a feldolgozás eredményét szubjektív szempontok alapján történő elvetésük kérdéses



# Miért fontos a robusztus mérésfeldolgozás?

- Feltételezzük a nagy számok törvényének teljesülését, DE a tapasztalat szerint nem minden esetben igaz
- A klasszikus mérésfeldolgozási eljárások optimális becslést adnak jól meghatározott paraméteres modellekre, DE:
  - nem foglalkoznak azzal, ha a modell csak közelítőleg igaz
  - gyakran rosszul teljesítenek, ha akár csak kis eltérés is van a modellben

# Az adatok elemzésének különböző módszerei





Hampel (1986)



# A robusztus adatfeldolgozás célja

- az adatok zöméhez legjobban illeszkedő struktúra megkeresése
- rendellenes, eltérő pontok (durva hibák) vagy részstruktúrák azonosítása
- azoknak az adatoknak az azonosítása, amelyek nagymértékben befolyásolják az eredményt

# Melyik illesztést akarjuk?





# Rezisztencia és robusztusság

- Egy eljárás akkor **rezisztens**, ha indokolatlanul nem befolyásolja néhány kivágó érték (Wilks, 1995)
- Egy **robusztus** eljárás nem érzékeny az ideálistól kissé eltérő körülményekre, amely ideális körülményekre az eljárás optimális (Hampel, 1986)

„kissé eltérő”:

az összes pontban vannak kis eltérések

kevés pontban vannak nagy eltérések

# Kivágó érték fogalma

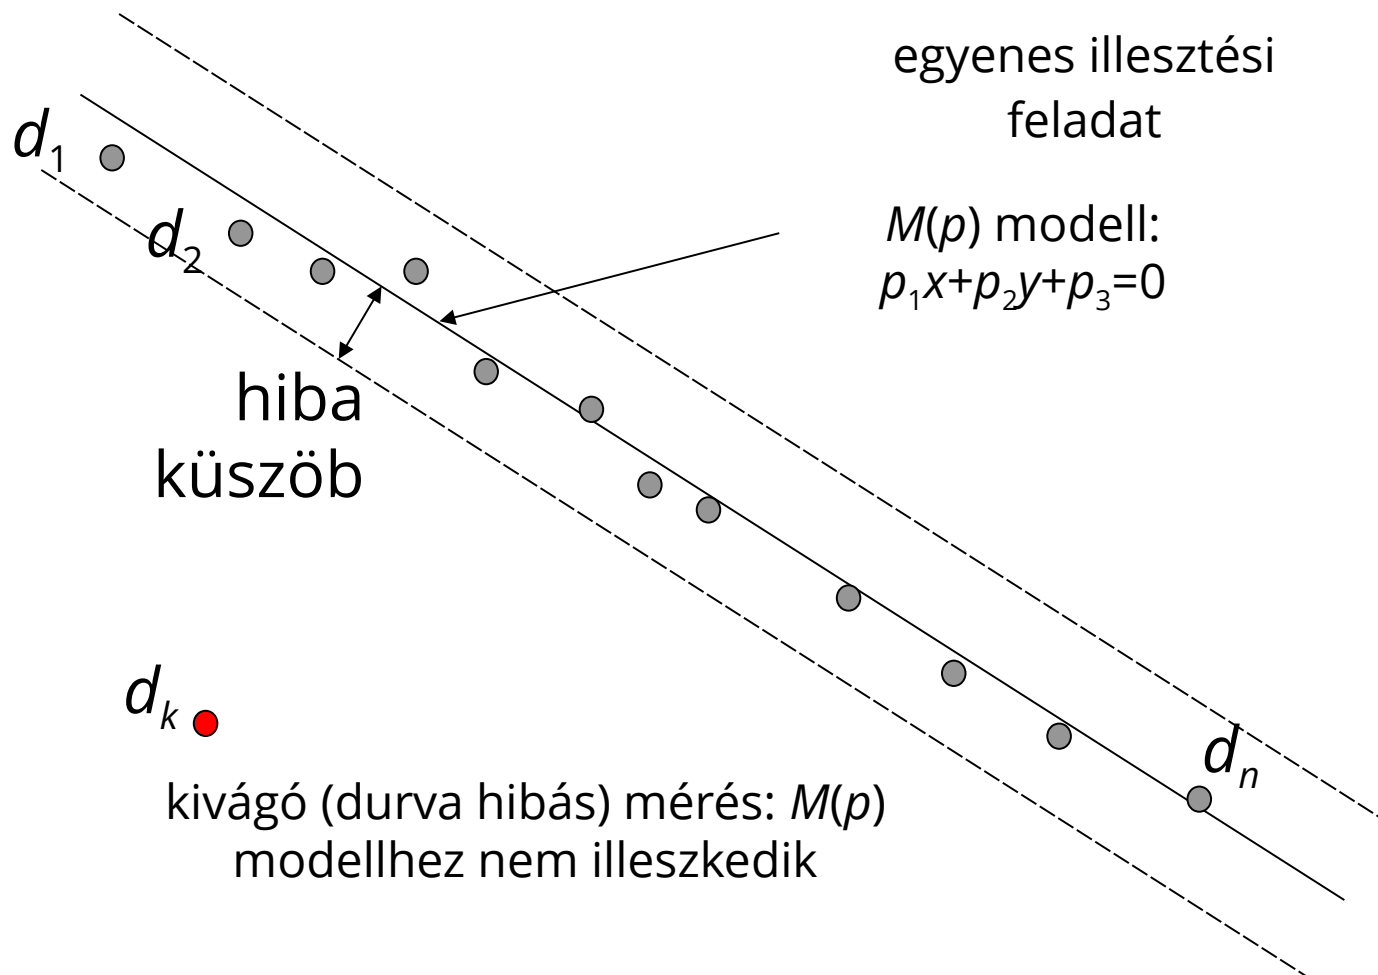
- Adott egy  $M$  modell és annak  $p$  („valódi”) paraméterei, amely (az elkerülhetetlen mérési hibáktól eltekintve) tökéletesen képes reprodukálni a  $d$  méréseket ( $d$ : „data”)
- Egy  $d$  mérés kivágó értéknek (durva hibásnak) tekinthető, ha nem illeszkedik valamely hiba küszöbön belül  $M$ -hez.

Ezt a hiba küszöböt a véletlen jellegű mérési hibák hatásának tulajdonítható maximális eltérés definiálja

A véletlen jellegű mérési hibák *eloszlása* ismert

Kapcsolódik a *rezisztencia* és a *robosztusság* fogalmaihoz

# Modell és mérések



# A becslés torzítása

- $D_I$  legyen a nem kivágó  $d$  mérések halmaza
- $D_{I/O}(m)$  legyen olyan  $d$  mérések halmaza, amelyben  $m$  darab nem kivágó mérést kicseréltünk kivágó (durva hibás) mérésekre
- ( $I$ : inlier,  $O$ : outlier)
- Legyen  $M(p)$  a paraméteres modell
- Az  $M(p)$  paraméteres modellen alapuló paraméter becslés torzítása az a maximális zavarás, amely a paraméter vektor becslésében jelentkezik akkor, ha  $D_I$ -t kicseréljük  $D_{I/O}(m)$ -re

# A becslés összeomlási pontja

- A becslés *összeomlási pontja* a kivágó (durva hibás) méréseknek az a *minimális* aránya (százaléka), amelyet elérve a becslés torzítása akár *tetszőlegesen nagy* is lehet
- Megmutatható, hogy a *legkisebb négyzetek* szerinti paraméter becslés összeomlási pontja 0 %  
Akár *egyetlen* kivágó mérés is *tetszőleges* mértékben képes elrontani a LKN becslést!

# Robusztus és rezisztens becslés

- A modelltől való eltérések nem hagyhatók figyelmen kívül a gyakorlatban
  - P.J. Huber: 5-10%-os kivágó érték (durva hiba) inkább szabálynak látszik, nem kivételnek
- Olyan becslést szeretnénk, amely nem érzékeny az  $M(p)$  paraméteres modelltől való eltérésekre:
  - megváltozik a véletlen mérési hibák eloszlása, de nem változik lényegesen a becslés és pontossága: *robosztusság*
  - nem illeszkedő, kivágó adatok lépnek fel, de nem változik lényegesen a becslés: *rezisztencia*
  - a LKN becslés sem nem robusztus, sem nem rezisztens

# A becslés abszolút hatásfoka

- Az  $e$  abszolút hatásfok a Cramér-Rao határhoz viszonyított aszimptotikus szórásnégyzet az adott becslési eljárásra (viszonyismként  $e \leq 1$  vagy százalékban kifejezve  $e \leq 100\%$  )

$$e = \frac{A_{\min}^2}{A^2}$$

- Az aktuális  $f(x)$  -hez tartozó optimális eljárással csak  $e$  -szer annyi adat kell ugyanakkora pontossághoz

# Robusztusság


- Valamely *becslés* akkor nevezhető robusztusnak, ha az *eloszlástípusok széles tartományán* a gazdaságossága csak jelentéktelen mértékben csökken
- Egy statisztikai *algoritmus* akkor robusztus, ha az *anyaeloszlásban* bekövetkező *kicsiny eltérés* a *becslések eloszlásában* is *csak kis eltérést* eredményez




# Az $f_a(x)$ szupermodell

- $a$  : típusparaméter
- $a \rightarrow \infty$  : Gauss-eloszlás
- $a = 2$  : Cauchy-eloszlás
- $a = N + 1$  :  
 $N$  szabadságfokú  
Student-eloszlás

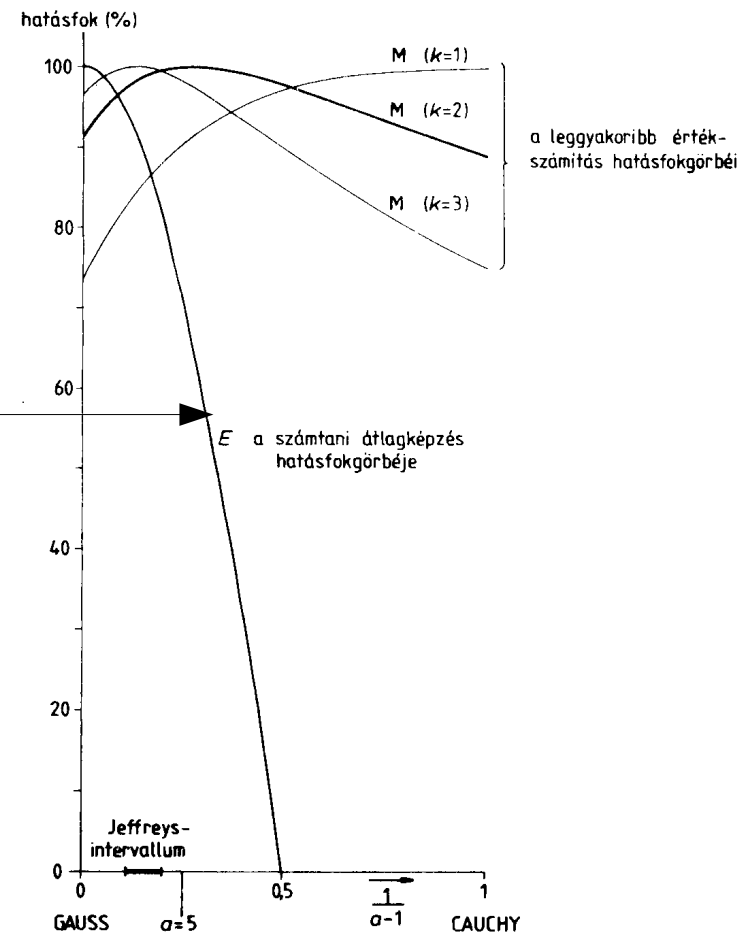
$$\frac{1}{a-1} = (0, 1) = (\text{Gauss}, \text{Cauchy})$$



# Robusztusság különböző becslésekre az $f_a(x)$ szupermodellre



LKN becslés  
nem robusztus



# Rezisztencia számszerűsítése – *IC*-függvény

- Milyen mértékben módosítja egyetlen  $x$  adat a helyparaméter becslés  $T$  eredményét?
- a válasz függ:
  - a becslés algoritmusától (legyen ez is  $T$ )
  - az aktuális  $F$  eloszlástól
  - az adat  $x$  értékétől
- $IC(x, F, T)$  hatásgörbe (*influence curve*, *IC*-görbe, *IC*-függvény adja meg a választ

# Az $IC$ -függvény definíciója

$$IC(x, F, T) = \lim_{t \rightarrow 0} \frac{T[(1-t) \cdot F + t \cdot H(x)] - T(F)}{t}$$

$H(x)$  az egységugrás (Heaviside) függvény

- Az  $IC$ -függvény megadja egyetlen,  $x$  értékű járulékos észlelésnek a  $T$  értékváltozásában megnyilvánuló hatását
- $T(F)$  az eredeti  $F$  eloszlás alapján becsült  $T$  paraméter
- $[(1-t) \cdot F + t \cdot H(x)]$  a megváltozott eloszlás
- $t$  a járulékos észlelés részaránya a többi adathoz képest

# A becslés értékének változása

- nagy  $n$  esetén közelítőleg  $\Delta T$  értékkel változik meg a  $T$  becslés értéke, ha az  $F$ -eloszlásfüggvényű eloszlásból származó  $n$  elemű mintánkhoz még egyetlen  $x$  értékű észlelést is figyelembe veszünk ( $t = 1/n$ ):

$$IC(x, F, T) = \frac{\Delta T}{1/n} \quad \Delta T = \frac{IC(x, F, T)}{n}$$

# Az $IC$ -görbe alkalmazása

- Közvetlen számszerű információt ad arról, hogy a durva hibájú adatok milyen mértékben torzítják az adott algoritmus szerint számított hely (vagy skála) paraméter becslés értékét (**rezisztencia**)
  - a számtani átlag  $IC$ -függvénye  $x$ -szel egyenlő
  - nem rezisztens
- a minta egy  $x$  értékű eleme milyen mértékben vesz részt a helyparaméter becslés értékének kialakításában (**robosztusság**)

# A becslés pontosságának növekedése az $n$ mintaelemszámmal

- Az  $n$  mintaelemszám növekedésével pontosságnövekedést várunk (a bizonytalanság csökkenését)
  - Ha ez valóban teljesül, azt mondjuk, hogy „teljesül a nagy számok törvénye”
- Nem robusztus becslési algoritmusoknál előfordulhat, hogy a pontosság *romlik*  $n$  növekedésével („fordítva teljesül a nagy számok törvénye”)

# Becslések határeloszlásai

- Ha a becslések eloszlása növekvő  $n$  mintaelemszám esetén egy eloszlástípust közelít, ezt *határeloszlásnak* hívjuk
- A határeloszlás kiszámításához már a legegyszerűbb becslés: a számtani átlagképzés esetén is szükség van a *karakterisztikus függvény* fogalmára
- A számtani átlagok határeloszlása véges  $\sigma$  esetén elvezet a *centrális határeloszlástétel*hez
- Az átlagok előbb-utóbb mindig  $1/\sqrt{n}$  szerint válnak pontosabbá? Egyáltalán pontosabbá válnak minden esetben?



# Számtani átlag határeloszlása

- Összeg és átlag sűrűségfüggvénye
- A karakterisztikus függvény fogalma
- Számtani átlagok határeloszlása véges  $\sigma$  esetén
- A centrális határeloszlástétel
- A nagy számok törvényének teljesülése és nem teljesülése

# Összeg sűrűségfüggvénye

- Hogyan adódhat egy konkrét érték, pl. 0.45 két érték összegeként?

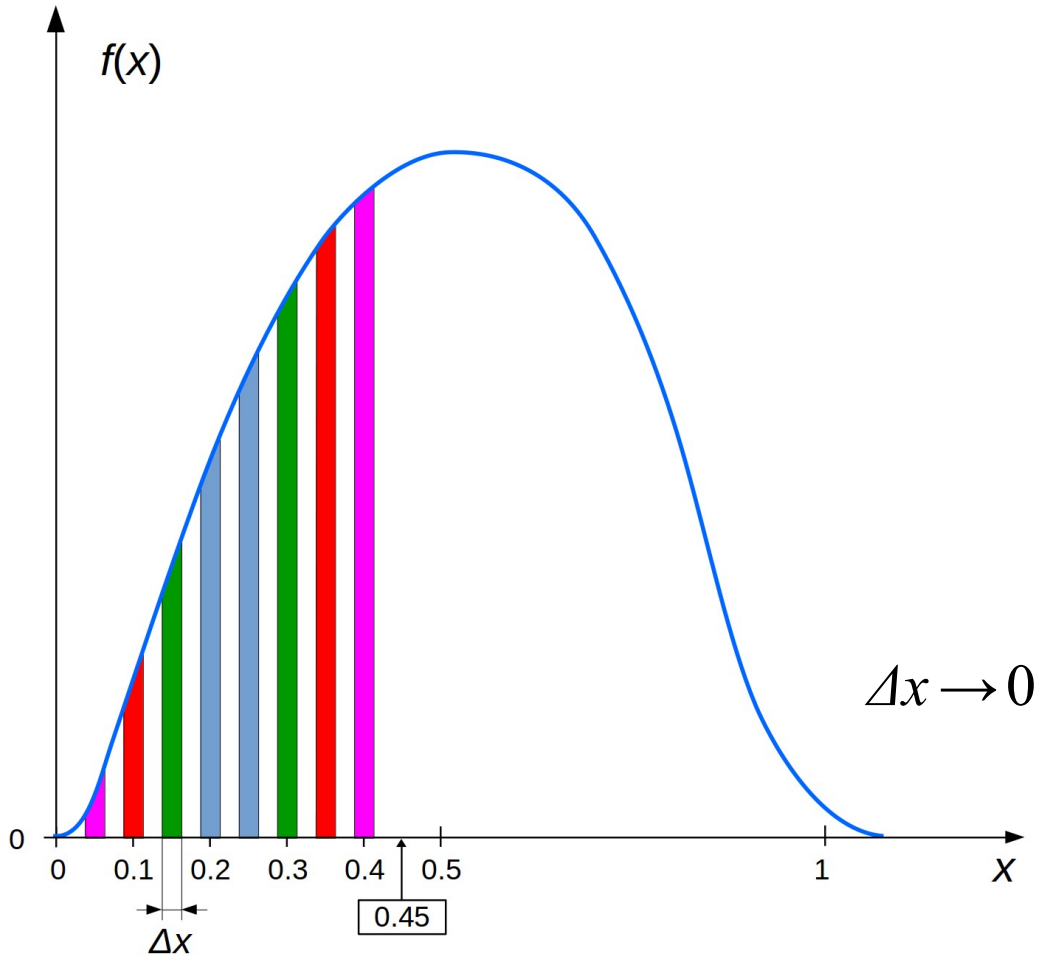
$$0.45 = 0.05 + 0.40$$

$$0.45 = 0.10 + 0.35$$

$$0.45 = 0.15 + 0.30$$

$$0.45 = 0.20 + 0.25$$

# Összeg $h(x)$ sűrűségfüggvénye



$$\begin{aligned} p(0.45) &= f(0.05) \cdot f(0.4) \cdot (\Delta x)^2 \\ &\quad + f(0.1) \cdot f(0.35) \cdot (\Delta x)^2 \\ &\quad + f(0.15) \cdot f(0.3) \cdot (\Delta x)^2 \\ &\quad + f(0.2) \cdot f(0.25) \cdot (\Delta x)^2 \end{aligned}$$

$$p(0.45) = \sum f(x) \cdot f(0.45 - x) \cdot (\Delta x)^2$$

$$h(0.45) = \int_0^{0.45} f(x) \cdot f(0.45 - x) dx$$

$$h(z) = \int_{-\infty}^{\infty} f(x) \cdot f(z - x) dx$$

# Összeg sűrűségfüggvénye

- Két különböző valószínűség sűrűségű eloszlásból az összeg sűrűségfüggvénye *konvolúcióval* számítható ki:

$$h(z) = \int_{-\infty}^{\infty} f(x) \cdot g(z-x) dx = f(x) * g(x)$$

- $n$  tagú összegre  $n$  tényezős konvolúció:

$$h(z) = f(x) * f(x) * f(x) \cdots f(x) = [f(x)]^{n*}$$

# Számtani átlag sűrűségfüggvénye

- $n$ -el való osztással  $1/n$ -szeresére csökken a sűrűségfüggvény szélessége, vagyis a skála paraméter  $1/n$ :



$$g^{(n)}(x) = n \cdot [f(nx)]^{n*}$$

- $[-1, 1]$  közötti egyenletes eloszlásra

$$g_u^{(n)}(x) = \frac{n}{2^n (n-1)!} \sum_{k=0}^{\text{int}\left(\frac{n+x}{2}\right)} (-1)^k \binom{n}{k} (n-2k+nx)^{n-1}$$

# Számtani átlag sűrűségfüggvénye

- $[-1, 1]$  közötti egyenletes eloszlásra (Steiner, 1990)



$q$  interkvartilis  
félterjedelem

Gauss-eloszláshoz  
közeledik és  $q$   
csökken

# Számtani átlag sűrűségfüggvénye

- Minden esetben tapasztalható az átlagok  $\sqrt{n}$ -nel növekvő pontossága?
- Minden esetben tapasztalható az átlagok Gausshoz tartozó eloszlása?

A válasz mindkét kérdésre: NEM

# Tanulságos példa - Tukey modell

- A kivágó értékek Tukey (1960) által bevezetett modellje

két Gauss-típusú sűrűségfüggvény lineáris kombinációja

$$f_T(x) = \frac{1}{\sqrt{2\pi}} \left\{ (1-p) e^{-x^2/2} + \frac{p}{\sigma_c} \cdot e^{-x^2/(2\sigma_c^2)} \right\}$$

- $n$ -elemű minták számtani átlagainak sűrűségfüggvénye:

$$g_T^{(n)}(x) = \frac{n}{\sqrt{2\pi}} \sum_{k=0}^n \binom{n}{k} (1-p)^{n-k} \cdot p^k \cdot$$



$$\frac{1}{\sqrt{n-k+k\sigma_c^2}} \exp \left\{ -\frac{(nx)^2}{2[(n-k)+k\sigma_c^2]} \right\}$$



# Tukey modell számtani átlagainak sűrűségfüggvénye

(Steiner, 1990)

- A Tukey modell paraméterei:  $p = 0.25$ ,  $\sigma_C = 150$



**Végül** Gauss-eloszláshoz közeledik és  $q$  csökken

# A karakterisztikus függvény

- Az  $f(x)$  sűrűségfüggvénnyel jellemzett eloszlás *karakterisztikus függvénye*:

$$\varphi(t) = \int_{-\infty}^{\infty} e^{ixt} f(x) dx = \mathcal{F}^{-1}\{f(x)\}$$

- origóra szimmetrikus  $f(x)$ -ek esetén:

$$\varphi(t) = 2 \int_0^{\infty} \cos(xt) f(x) dx$$

# A karakterisztikus függvény

- Az  $f(x)$  sűrűségfüggvény a karakterisztikus függvény Fourier-transzformáltja:

$$f(x) = \mathcal{F}\{\varphi(t)\} = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-ixt} \varphi(t) dt$$

- origóra szimmetrikus  $\varphi(t)$ -k esetén:

$$f(x) = \frac{1}{\pi} \int_0^{\infty} \cos(xt) \varphi(t) dt$$

- $S$  skála paraméterű sűrűségfüggvényre a karakterisztikus függvény

$$\frac{1}{S} \int_{-\infty}^{\infty} e^{i\frac{x}{S}St} f\left(\frac{x}{S}\right) dx = \int_{-\infty}^{\infty} e^{iuSt} f(u) du = \varphi(St)$$

# A karakterisztikus függvények táblázata

Eloszlástípus vagy szupermodell		A $\varphi(t)$ karakterisztikus függvény (a standard alakhoz)
<i>eloszlások:</i>		
egyenletes	$f_u(x)$	$\frac{\sin t}{t}$
Gauss	$f_G(x)$	$e^{-t^2/2}$
Laplace	$f_L(x)$	$\frac{1}{1+t^2}$
Cauchy	$f_C(x)$	$e^{- t }$
exponenciális	$f_e(x)$	$\frac{1}{1-it}$
<i>szupermodellek:</i>		
$f_a(x)$		
speciális esetek:		
$a=2$ esetén [l. $f_C(x)$ ]		$e^{- t }$
$a=4$ esetén		$(1+ t ) \cdot e^{- t }$
$a=6$ esetén		$(1+ t +t^2/3) \cdot e^{- t }$
(általános $a$ esetén a karakterisztikus függvény csak harmadfajú módosított Bessel-függvényekkel írható fel)		

# Számtani átlagok határeloszlása

## véges $\sigma$ esetén

- Az  $f(x)$  eloszlásból származó  $n$  elemű minta alapján meghatározott átlagok  $f^{(n)}(x)$  sűrűségfüggvénye

$$f^{(n)}(x) = n \cdot [f(nx)]^{n*}$$

- Az  $n$  elemű átlagok karakterisztikus függvénye

$$\varphi^{(n)}(t) = \left[ \varphi\left(\frac{t}{n}\right) \right]^n$$

# Számtani átlagok határeloszlása

## véges $\sigma$ esetén

- Az átlagok  $f^{(n)}(x)$  sűrűségfüggvénye helyett azok  $\sqrt{n}$ -szeresének  $f(x)$  sűrűségfüggvényét vizsgáljuk. Ennek karakterisztikus függvénye

$$\bar{\varphi}^{(n)}(t) = \left[ \varphi\left(\frac{t}{\sqrt{n}}\right) \right]^n$$

- Az origóra szimmetrikus  $f(x)$  sűrűségfüggvény esetében a  $\varphi(t/\sqrt{n})$  Taylor-polinomjával

$$\bar{\varphi}(t) = \left[ \varphi(0) + \varphi''(0) \frac{t^2}{2n} + O\left(\frac{t^2}{n}\right) \right]^n$$

# Számtani átlagok határeloszlása véges $\sigma$ esetén

- A páratlan hatványok  $f(x)$  szimmetriája miatt zérusok és
$$\varphi(0) = 1$$
- A Fourier transzformáció tulajdonságai miatt

$$\left. \frac{d^m \varphi(t)}{dt^m} \right|_{t=0} = i^m \cdot \int_{-\infty}^{\infty} x^m \cdot f(x) dx$$

tehát (ha a szórás véges)

$$\varphi''(0) = - \int_{-\infty}^{\infty} x^2 \cdot f(x) dx = -\sigma^2$$

# Számtani átlagok határeloszlása véges $\sigma$ esetén

- Az átlagok  $\sqrt{n}$ -szeresének karakterisztikus függvénye

$$\bar{\varphi}(t) = \left[ 1 - \frac{\sigma^2 t^2}{2n} + O\left(\frac{t^2}{n}\right) \right]^n$$

- A következő jelölést bevezetve:  $c_n = -\frac{\sigma^2 t^2}{2} + n \cdot O\left(\frac{t^2}{n}\right)$

$$\bar{\varphi}(t) = \left[ 1 + \frac{c_n}{n} \right]^n \quad \text{és} \quad \lim_{n \rightarrow \infty} \bar{\varphi}(t) = \lim_{n \rightarrow \infty} \left( 1 + \frac{c_n}{n} \right)^n = e^{\lim_{n \rightarrow \infty} c_n}$$



# Számtani átlagok határeloszlása

## véges $\sigma$ esetén

- Az átlagok  $\sqrt{n}$ -szeresének karakterisztikus függvénye  $n \rightarrow \infty$  esetén:

$$\lim_{n \rightarrow \infty} \bar{\varphi}(t) = e^{\lim_{n \rightarrow \infty} c_n} = e^{-\sigma^2 t^2 / 2}$$

amiből viszont

$$\bar{f}(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}}$$

- Tehát nagy  $n$ -eknél  $\sigma/\sqrt{n}$  szórássú Gauss eloszlást közelít az átlagok eloszlása,  $f(x)$  definíciója miatt

# Nagy számok törvénye

- Nagy  $n$ -eknél  $\sigma/\sqrt{n}$  szórássú Gauss eloszlást közelít az átlagok eloszlása
- Ez a *nagy számok törvénye*, ami egy becslési mód, az átlagképzés  $\sqrt{n}$ -el arányos pontosságnövekedéséről tudósít nagy  $n$ -ek esetén

# Centrális határeloszlástétel

- Nagy  $n$ -eknél  $\sigma/\sqrt{n}$  szórású Gauss eloszlást közelít az átlagok eloszlása
- Ez *határeloszlástétel*, mert az átlagok (mint becslések) eloszlásának a típusát is szolgáltatja  $n \rightarrow \infty$  esetén
- A *centrális* jelző utal a hagyományos (átlag-szórás) statisztikában betöltött központi szerepére

# Átlagok eloszlása Cauchy-eloszlás esetén

- Nincs véges szórása a Cauchy-eloszlásnak  
a *véges szórás feltétele* a centrális határeloszlás tétele érvényességének
- Standard Cauchy-eloszlás esetében az átlagok karakterisztikus függvénye

$$\varphi^{(n)}(t) = \left[ \varphi\left(\frac{t}{n}\right) \right]^n = [e^{-|t/n|}]^n = e^{-|t|}$$

- Bármilyen  $n$ -re az átlagok eloszlását *ugyanaz* az  $f_c(x)$  sűrűségfüggvény írja le  
*semmilyen formában nem teljesül* az átlagokra a nagy számok törvénye  
szó sincs arról, hogy az átlagok nagy  $n$ -ekre Gauss-eloszlást közelítenek











# Aszimptotikus szórás

- Ha valamely *becsléseloszlás* Gauss-típusú  $A/\sqrt{n}$  szórással,  $A$ -t *aszimptotikus szórásnak* nevezzük
- Az *átlagképzés*  $A_E$  aszimptotikus szórása azonos az *anyaeloszlás*  $\sigma$  szórásával
- A szórás kapcsolata az interkvartilis féltérjedelemmel Gauss-eloszlás esetén  $q = 0.6745\sigma$ , tehát az átlagképzésre a



$$\frac{q_n}{A_E \cdot 0.6745}$$

hányadosokat ábrázoló pontok egy  $1/\sqrt{n}$  abszcisszájú koordináta-rendszerben az origóból induló 45°-os egyenesen vannak

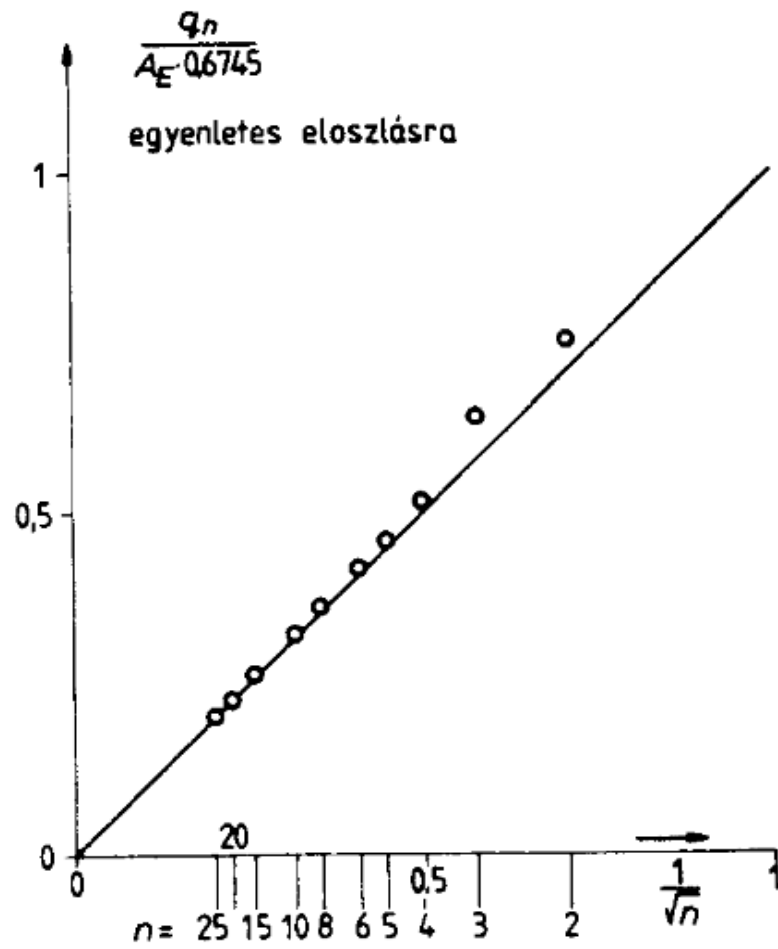
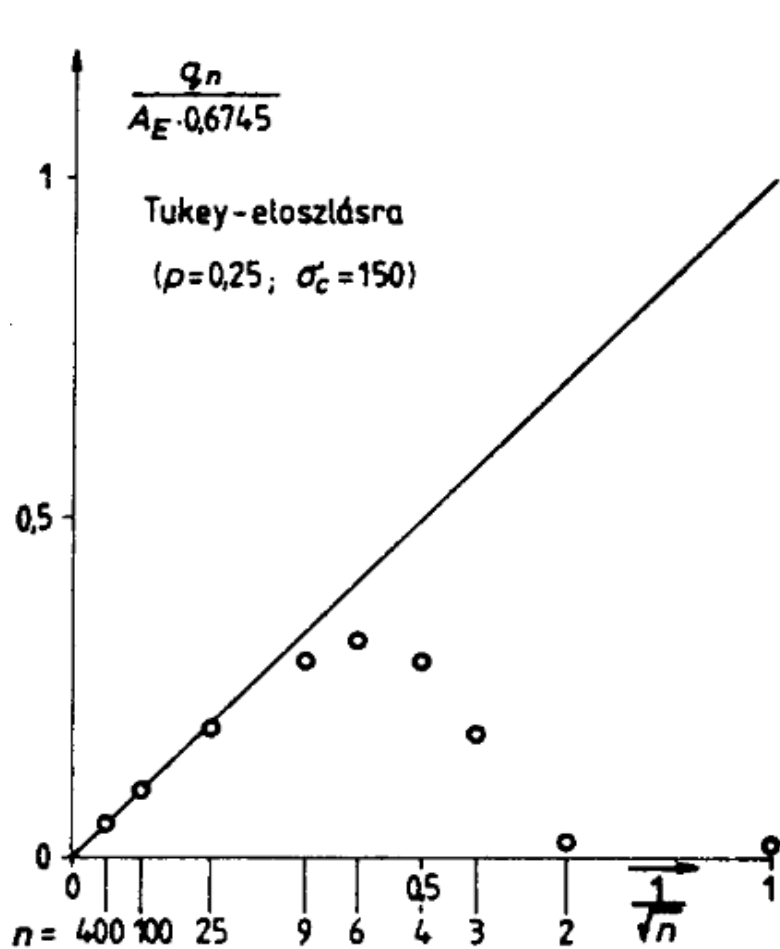
# Számtani átlag sűrűségfüggvénye



# Tukey modell számtani átlagainak sűrűségfüggvénye


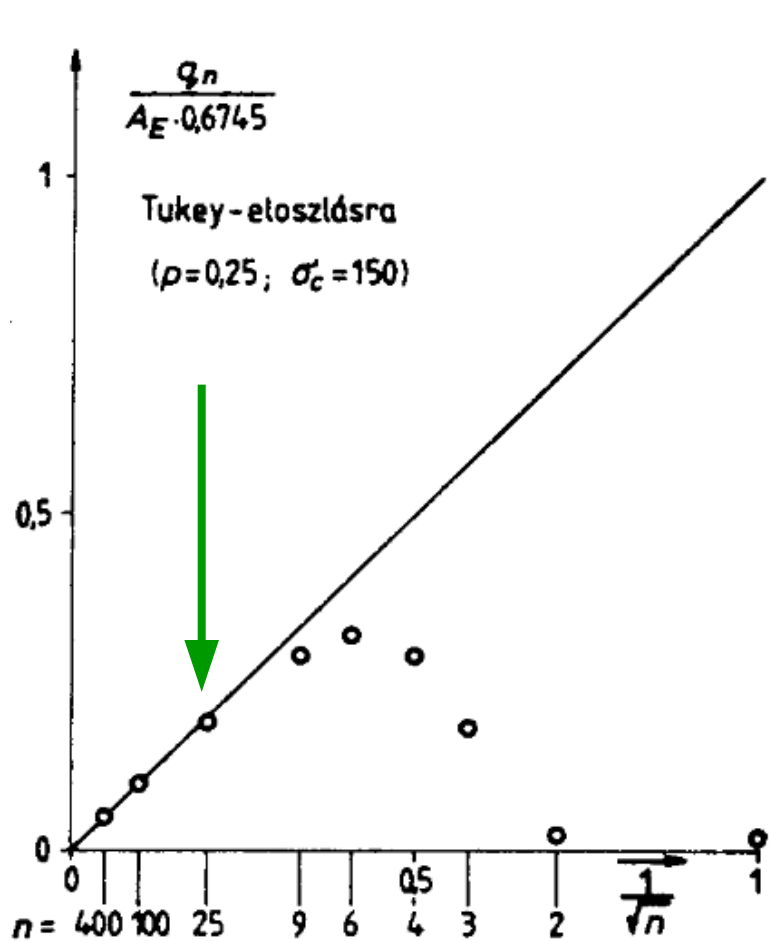


# Nagy számok törvényének teljesülése






# Nagy számok törvényének teljesülése




# Nagy számok törvényének nem teljesülése az $f_a(x)$ szupermodellre



- Az átlagok  $\sqrt{n}$ -el arányosan *egyre pontatlanabb becslései* az eloszlás szimmetriapontjának
- Az átlag mint becslés romlásának üteme az  $a$  típusparaméter-érték csökkenésével egyre nagyobb lesz
- A leggyakoribb értékek ezzel szemben a becslési pontosság  $\sqrt{n}$ -el arányos *növekedését* mutatják

# Leggyakoribb értékek becslése



A leggyakoribb értékek számításán alapuló becslések követik a  $\sqrt{n}$  szerinti pontosságnövekedést

# Korrelációs együttható rezisztenciája

- Hagyományosan: átlag, szórás

$$r_E = \frac{\sum_{i=1}^n (x_i - E_x) \cdot (y_i - E_y)}{\sqrt{\sum_{i=1}^n (x_i - E_x)^2} \cdot \sqrt{\sum_{i=1}^n (y_i - E_y)^2}}$$

# Korrelációs együttható rezisztenciája

- Rezisztensen: leggyakoribb érték, dihézió

$$r_M = \frac{\sum_{i=1}^n \frac{1}{\varepsilon_x^2 + (x_i - M_x)^2} (x_i - M_x) \cdot \frac{1}{\varepsilon_y^2 + (y_i - M_y)^2} (y_i - M_y)}{\sqrt{\sum_{i=1}^n \left( \frac{1}{\varepsilon_x^2 + (x_i - M_x)^2} \right)^2 (x_i - M_x)^2} \cdot \sqrt{\sum_{i=1}^n \left( \frac{1}{\varepsilon_y^2 + (y_i - M_y)^2} \right)^2 (y_i - M_y)^2}}$$


# Szám példa (Steiner F.)

- Két pontot ( (2, 0) és (8, 54) ) kivéve az összes pont egy  $-1$  meredekségű egyenesre esik:

$x_i$	0	1	2	3	4	5	6	7	8	9	10
$y_i$	32	31	0	29	28	27	26	25	54	23	22

- Átlag, szórás számítással  $r_E = +0.1695$
- Leggyakoribb érték, dihézió számítással  $r_M = -0.7833$

# Adatok



# Regressziós egyeneselek

- Hagyományosan: átlag, szórás

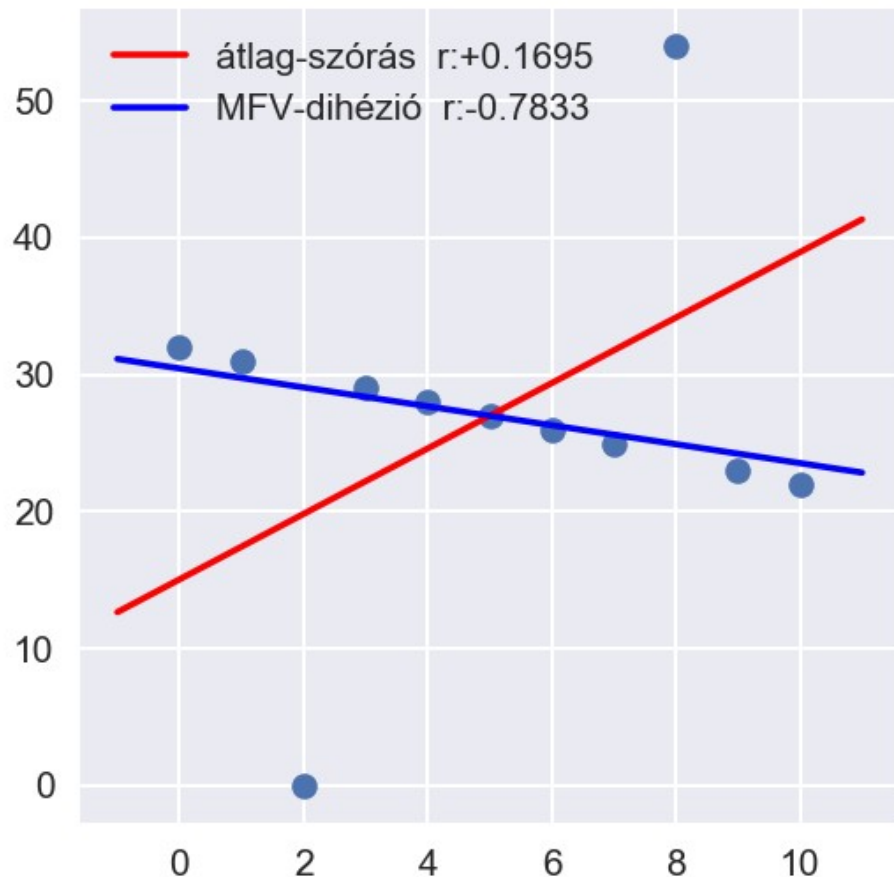
$$y = r_E \frac{\sigma_y}{\sigma_x} x + E_y - E_x r_E \frac{\sigma_y}{\sigma_x}$$

- Rezisztensen: leggyakoribb érték, dihézió

$$y = r_M \frac{\varepsilon_y}{\varepsilon_x} x + M_y - M_x r_M \frac{\varepsilon_y}{\varepsilon_x}$$



# Regressziós egyenesek



- Melyik regressziós egyenest szeretnénk?

# Összefoglalás

- Robusztus és rezisztens mérésfeldolgozási eljárások felhasználásával érhetjük csak el, hogy
  - a mérések eloszlására érzéketlen legyen a számítás (becslés) eredménye
  - a kivágó értékek ne befolyásolják indokolatlan mértékben az eredményeket
  - megkapjuk az elvárt pontosságnövekedést a mérések számának növelésével



# Tananyag, szakirodalom

- Steiner (1990): 5.5
- Vincze (1968): 2.5
- Hampel F.R, Ronchetti E.M, Rousseeuw P.J, Stahel W.A (1986): Robust Statistics. The Approach Based on Influence Functions. Wiley & Sons