



4. előadás

Kiegyenlítő számítások MSc

2018/19



Áttekintés

- Extrém érték elmélet
- Monte Carlo eljárások

Extrém érték elmélet

- Bevezetés
- Alapvető módszerek (GEV és POT)
- Extrém érték eloszlások
- Alkalmazás: GNSS integritás vizsgálat

Bevezetés


- Az extrém érték elmélet (extreme value theory, EVT) célja olyan *események valószínűségének a becslése*, amelyek kívül esnek a megfigyelt adatok körén
- ilyen események lehetnek
 - szélsőséges időjárási események
 - földrengések, erdőtüzek
 - GNSS életvédelmi célú szolgáltatás meghibásodása
 - nagy kárértékű biztosítási események
 - gépalkatrészek tönkremenetele (kifáradás, korrózió)
 - tőzsdekrach

Bevezetés

- Az extrém érték elmélet alapvetően extrapolációt jelent a mérési adatok körén kívülre
 - könnyen kritizálható, természeténél fogva nem megbízható
 - modell feltevéseken alapszik, a valóság ennél mindig összetettebb
- Szilárd matematikai alapokon nyugszik
 - nem javasoltak még más hihető alternatívát helyette
 - a meglevő adatok legjobb felhasználására törekszik az extrém események valószínűségének kiszámítása céljából
- Óvatosságra van szükség az alkalmazása során

Hagyományos és extrém érték statisztika

- hagyományos statisztika: az átlagos viselkedésre összpontosít
 - központi határeloszlás tétel
- extrém érték elmélet: a rendkívüli és ritka értékekre összpontosít
 - Fisher-Tippett tétel



Alapvető módszerek

- Klasszikus (blokk) módszerek
(GEV = Generalized Extreme Value)
 - adott időszakon (blokk) belüli maximum értékekkel foglalkozik – mi legyen az adott időszak?
- Küszöb feletti értékek elemzési módszere
(POT = Peak Over Threshold)
 - adott küszöbérték feletti értékekkel foglalkozik – mi legyen az adott küszöbérték?

Közös jellemzők

- az extrém érték elmélet általánosan alkalmazható függetlenül a mért adatok eloszlásának (pl. Gauss eloszlás) feltételezésétől
- az eloszlások szélei az adatok és néhány általánosságban igaz feltételezés alapján meghatározhatók akkor is, ha nincs adat ebből a tartományból

Eloszlásfüggvények

- **Blokk maximum**

$$M_n = \max \{ X_1, \dots, X_n \}$$

ha $n \rightarrow \infty$, akkor

M_n általánosított extrém érték (GEV) eloszlást követ

- **Küszöb feletti értékek**

$$\{ X_i - u \mid X_i > u \}$$

nagyon nagy u küszöb esetén

általánosított Pareto-féle eloszlást követ

GEV – Fisher-Tippett tétel

$M_n = \max \{X_1, \dots, X_n\}$ eloszlása ($n \rightarrow \infty$)

$$\xi \neq 0 \quad G(y) = \exp \left(- \left[1 + \xi \left(\frac{y - \mu}{\sigma} \right) \right]^{\frac{-1}{\xi}} \right)$$

$$\xi = 0 \quad G(y) = \exp \left(- \exp \left(\frac{y - \mu}{\sigma} \right) \right)$$

ami az **általánosított extrém érték eloszlás (GEV)**

paraméterek: μ hely, σ skála, ξ alak

GEV eloszlás típusok

ξ alak paramétertől függően 3 típusa van

Gumbel $\xi = 0$

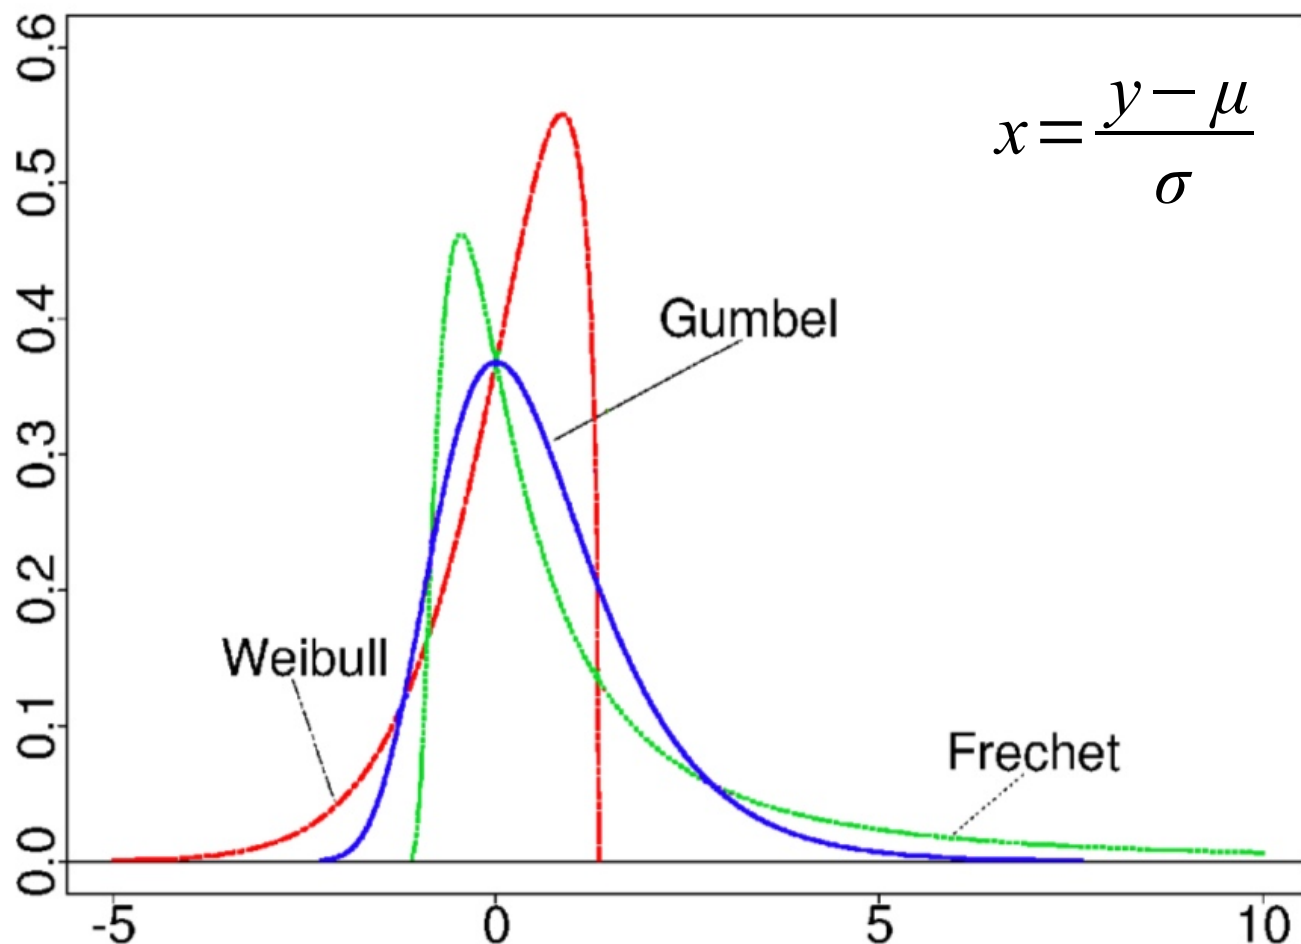
$$G(x) = \exp(-\exp[x])$$

Fréchet $\xi = 1/\alpha > 0$

$$G(x) = \exp\left(-\left[1 + \frac{x}{\alpha}\right]^{-\alpha}\right)$$

Weibull $\xi = -1/\alpha < 0$

$$G(x) = \exp\left(-\left[1 + \frac{x}{\alpha}\right]^{\alpha}\right)$$



GEV eloszlás típusok

ξ alak paramétertől függően 3 típusa van

Gumbel $\xi = 0$


exponenciális szárny

Fréchet $\xi = 1/\alpha > 0$

súlyos szárny

Weibull $\xi = -1/\alpha < 0$

felső végpont



GEV eloszlások

- A $\{X_1, \dots, X_n\}$ mintára, melyből a maximumok származnak:
- X_i -k azonos eloszlású, egymástól független valószínűségi változók legyenek

Visszatérési szintek

- Adott idő (pl. 25, 50, 100 év) alatt várhatóan egyszer kapunk ilyen vagy magasabb értéket
- Ha E év alatt egyszer tér vissza: $p = 1/E$
- GEV p -kvantilise: $G(z_p) = 1 - p$

$$\xi \neq 0 \quad z_p = \mu - \frac{\sigma}{\xi} \exp\left(1 - y_p^{-\xi}\right)$$

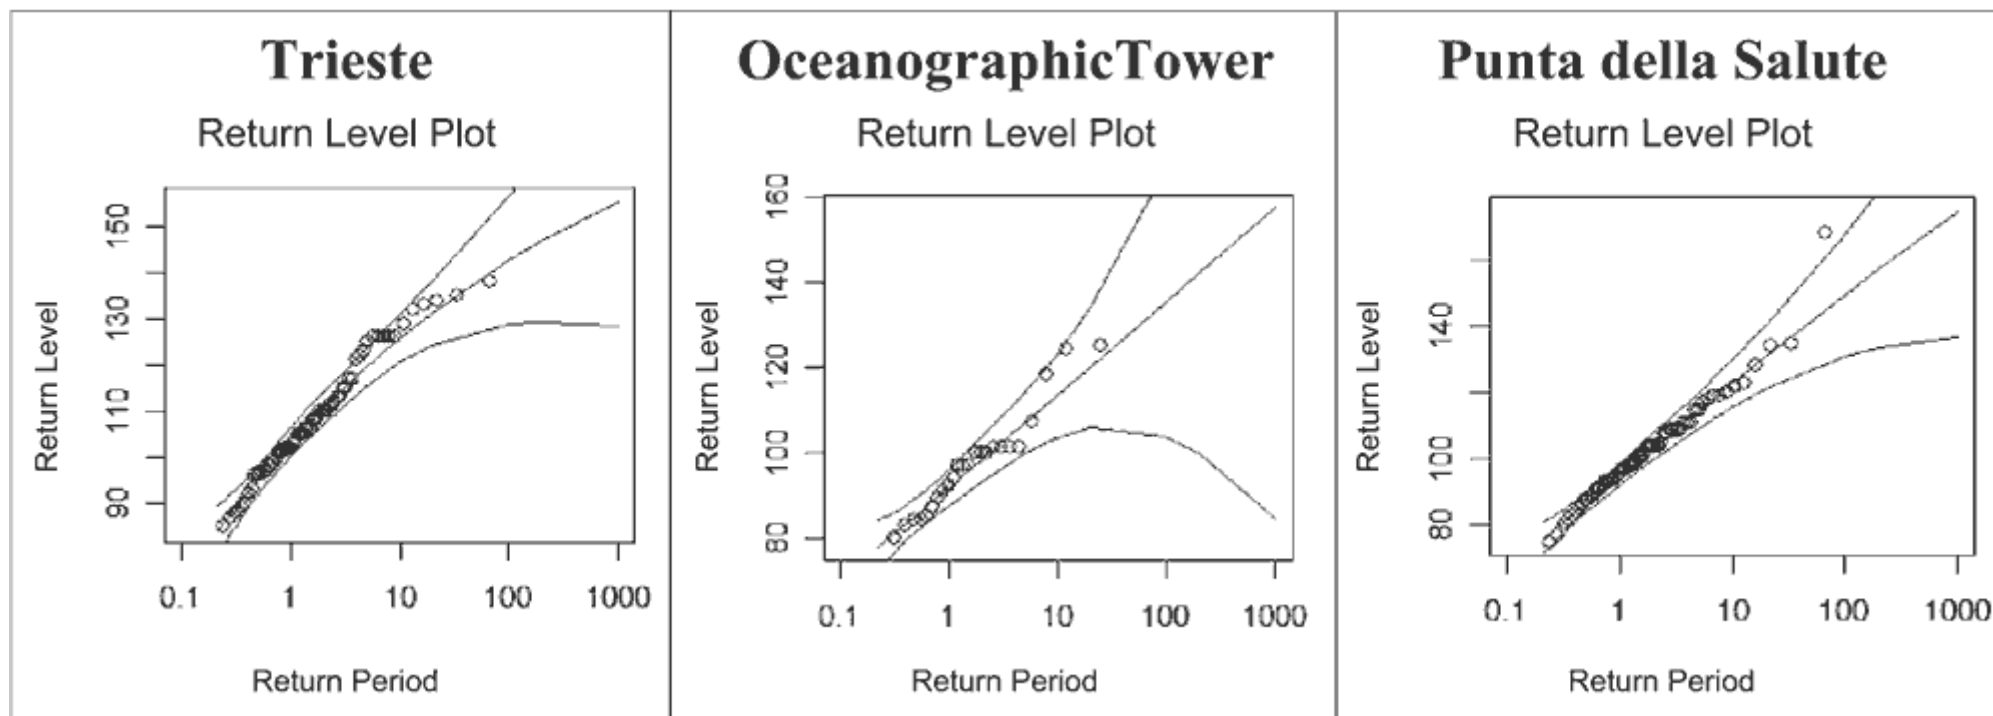
$$\xi = 0 \quad z_p = \mu - \sigma \log y_p$$

ahol $y_p = \log(1 - p)$

Visszatérési szint görbe

- ábrázoljuk z_p -t $\log(1 - p)$ -vel szemben logaritmikus skálán
 - lineáris (egyenes), ha $\xi = 0$
 - konvex görbe, határértéke $\mu - \frac{\sigma}{\xi}$, ha $\xi < 0$
 - konkáv görbe, ha $\xi > 0$

Pirazzoli et al. 2007



Küszöb feletti értékek (POT)

- Azok az események extrémek, amelyek meghaladnak egy küszöböt
- Ha a küszöb elég magas, az azt meghaladó adatok hasonlóan viselkednek
- Előnye, hogy általában több adatunk van
- A küszöbérték helyes megválasztása kritikus pont

POT eloszlása

- Az $Y_i = \{X_i - u \mid X_i > u\}$, vagyis egy u küszöbértéket meghaladó X_i értékek eloszlása nagy u értékekre ($u \rightarrow \infty$)

általánosított Pareto-féle eloszlást követ (GPD)

paraméterek: σ skála, ξ alak


$$H(y \mid X_i > u) = 1 - \left(1 + \xi \frac{y}{\sigma_u}\right)^{-\frac{1}{\xi}}$$

Küszöb választása: átlagos meghaladás ábra

- Tetszőleges u küszöbre ábrázoljuk az $X_i - u$ várható értékét (átlagát) azokra a megfigyelésekre, melyekre $X_i > u$ az u függvényében
- Ha a Pareto modell igaz, akkor ez a görbe közelítőleg *lineáris* lesz
- Tehát úgy kell megválasztanunk a küszöb értékét, hogy a görbe már lineáris legyen

Átlagos meghaladás ábra

- R csomag: 'evir', meplot(danish)



POT eloszlás típusok

ξ alak paramétertől függően 3 típusa van

Gumbel $\xi = 0$ exponenciális szárny

$$H(y) = 1 - \exp\left(-\frac{y}{\sigma_u}\right)$$

Pareto(Fréchet) $\xi > 0$ súlyos szárny

$$1 - H(y) \sim cy^{-\frac{1}{\xi}}$$

Weibull $\xi < 0$ felső végpont


$$\omega_F = \frac{\sigma_u}{|\xi|}$$

Küszöb választás: paraméter - u ábra

- Tetszőleges u küszöbre ábrázoljuk a ξ vagy a σ paraméter becsült értékét azokra a megfigyelésekre, melyekre $X_i > u$ az u függvényében
- Ha a Pareto modell igaz, akkor ez a görbe közelítőleg *konstans* lesz
- Tehát úgy kell megválasztanunk a küszöb értékét, hogy a görbe konstans legyen

$\xi(u)$ stabilitás ábra (parameter stability plot)

- R csomag: 'evir', shape(danish)

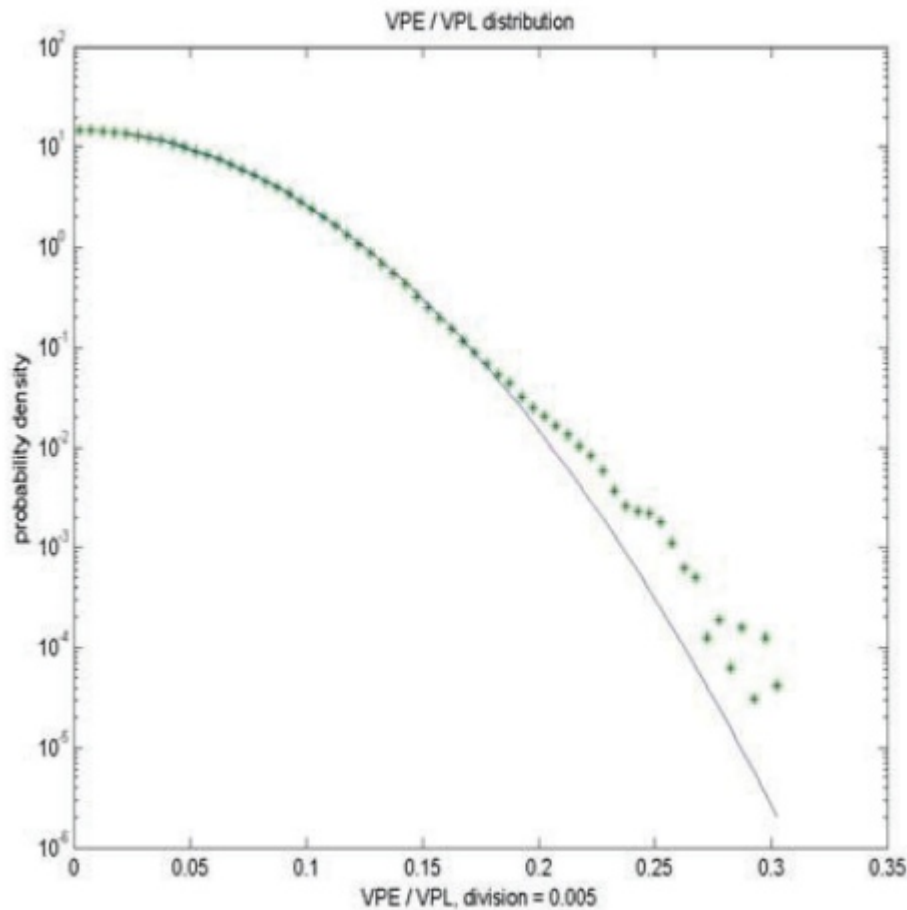


Alkalmazás: GNSS integritás vizsgálat

- légi irányítás szempontjából (ICAO LPV) a hiba (MI: Misleading Information) elfogadható maximális valószínűsége $2 \cdot 10^{-7}$ 150 s alatt (24 évente 1)
 - klasszikus statisztikai módszerekkel nem kezelhető
- extrém érték elmélet jól használható az MI valószínűség becsléséhez
 - GIMAT: GNSS Integrity Monitoring and Analysis Tool

VPE/VPL

- VPE: magassági pozíció hiba
- VPL: magassági biztonsági szint
- $VPE/VPL > 1$:= ML (félrevezető információ)

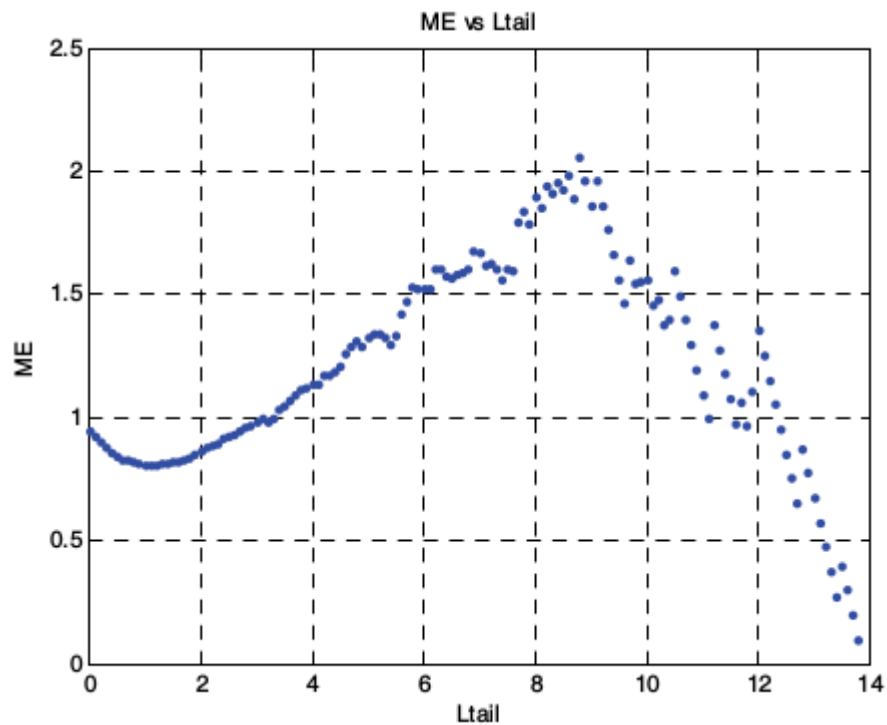


3 havi GPS/EGNOS
adatok
(> 6 millió epocha)
vonal: Gauss-eloszlás

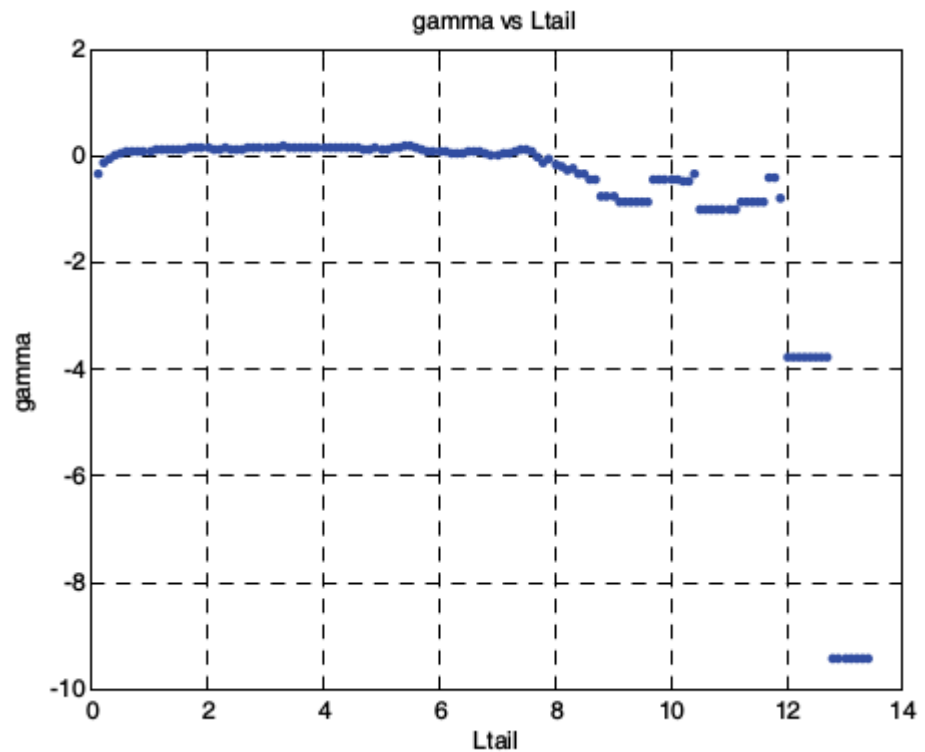
Veerman et al. 2009

Extrém érték elmélet alkalmazása (GIMAT)

átlagos meghaladás ábra



paraméter stabilitás ábra



Monte Carlo eljárások

- Számítási algoritmusok széles köre, melyek ismételt véletlen mintavételezéssel állítanak elő számszerű eredményeket
- Hagyományos eszközökkel nehezen vagy egyáltalán nem vizsgálható problémák
- Fő alkalmazási területek:
 - optimalizáció
 - numerikus integrálás
 - adott eloszlás szerinti minta generálása


Lépések

- 1) Meghatározzuk a lehetséges értékek tartományát
- 2) A tartományon megadott eloszlás szerint véletlen mintákat állítunk elő
- 3) A mintákon valamilyen előírt számítást végzünk
- 4) Összesítjük a kapott eredményeket

Mintavétel tetszőleges valószínűségeloszlásból

- Rendelkezünk a $(0, 1)$ intervallumban egyenletes eloszlású véletlenszámokat szolgáltató eljárással
- Az $F(x)$ eloszlásfüggvényű valószínűségeloszlásból szeretnénk n elemű mintát venni
- Ismerjük az $F(x)$ eloszlásfüggvény inverzét, az $F^{-1}(y) = F^{-1}(p)$ kvantilis függvényt
- Előállítunk n db y_i egyenletes eloszlású véletlenszámot ($i = 1, \dots, n$)
- Az $x_i = F^{-1}(y_i)$ a keresett n elemű minta

Mintavétel tetszőleges valószínűségeloszlásból



$$y_i = F(x_i)$$

$$x_i = F^{-1}(y_i)$$


$F^{-1}(p)$ kvantilis függvény

Analitikusan megadható kvantilis függvények

Density $f(x)$	$F(x)$	$X=F^{-1}(U)$	Simplified form
Exponential(λ) $\lambda e^{-\lambda x}, x \geq 0$	$1 - e^{-\lambda x}$	$-\frac{1}{\lambda} \log(1-U)$	$-\frac{1}{\lambda} \log(U)$
Cauchy(σ) $\frac{\sigma}{\pi(x^2 + \sigma^2)}$	$\frac{1}{2} + \frac{1}{\pi} \arctan\left(\frac{x}{\sigma}\right)$	$\sigma \tan\left(\pi\left(U - \frac{1}{2}\right)\right)$	$\sigma \tan(\pi U)$
Rayleigh(σ) $\frac{x}{\sigma} e^{-\frac{x^2}{2\sigma^2}}, x \geq 0$	$1 - e^{-\frac{x^2}{2\sigma^2}}$	$\sigma \sqrt{-\log(1-U)}$	$\sigma \sqrt{-\log(U)}$
Triangular on $(0, a)$ $\frac{2}{a}\left(1 - \frac{x}{a}\right), 0 \leq x \leq a$	$\frac{2}{a}\left(x - \frac{x^2}{2a}\right)$	$a(1 - \sqrt{1-U})$	$a(1 - \sqrt{U})$
Tail of Rayleigh $x e^{\frac{a^2 - x^2}{2}}, x \geq a > 0$	$1 - e^{\frac{a^2 - x^2}{2}}$	$\sqrt{a^2 - 2 \log(1-U)}$	$\sqrt{a^2 - 2 \log U}$
Pareto(a, b) $\frac{ab^a}{x^{a+1}}, x \geq b > 0$	$1 - \left(\frac{b}{x}\right)^a$	$\frac{b}{(1-U)^{1/a}}$	$\frac{b}{U^{1/a}}$

Elutasító mintavétel

- javasolt eloszlából vett minta elfogadása/elutasítása



- cél eloszlás
- javasolt eloszlás
- elfogadjuk a mintát
- elutasítjuk a mintát

Véletlenszám generátorok

- fontos szempontok:
 - statisztikai minőség
 - előrejelezhetőség
 - reprodukálható eredmények
 - ismétlési periódus
 - futásidő
 - tárigény
 - kódméret, bonyolultság
 - tetszőleges dimenzióban egyenletes eloszlás

	Statistical Quality	Prediction Difficulty	Reproducible Results	Multiple Streams	Period	Useful Features	Time Performance	Space Usage	Code Size & Complexity	k-Dimensional Equidistribution
PCG Family	Excellent	Challenging	Yes	Yes (e.g. 2^{63})	Arbitrary	Jump ahead, Distance	Very fast	Very compact	Very small	Arbitrary*
Mersenne Twister	Some Failures	Easy	Yes	No	Huge 2^{19937}	Jump ahead	Acceptable	Huge (2 KB)	Complex	623
Arc4Random	Some Issues	Secure	Not Always	No	Huge 2^{1699}	No	Slow	Large (0.5 KB)	Complex	No
ChaCha20[†]	Good	Secure	Yes	Yes (2^{128})	2^{128}	Jump ahead, Distance	Fairly Slow	Plump (0.1 KB)	Complex	No
Minstd (LCG)	Many Issues	Trivial	Yes	No	Tiny $< 2^{32}$	Jump ahead, Distance	Acceptable	Very compact	Very small	No
LCG 64/32	Many Issues	Published Algorithms	Yes	Yes 2^{63}	Okay 2^{64}	Jump ahead, Distance	Very fast	Very compact	Very small	No
XorShift 32	Many Issues	Trivial	Yes	No	Small 2^{32}	Jump ahead	Fast	Very compact	Very small	No
XorShift 64	Many Issues	Trivial	Yes	No	Okay 2^{64}	Jump ahead	Fast	Very compact	Very small	No
RanQ	Some Issues	Trivial	Yes	No	Okay 2^{64}	Jump ahead	Fast	Very compact	Very small	No
XorShift* 64/32	Excellent	Unknown?	Yes	No	Okay 2^{64}	Jump ahead	Fast	Very compact	Very small	No

Eloszlásfüggvények terjedése nem lineáris rendszeren keresztül

- Ismert a vizsgált rendszer modellje: $\mathbf{y} = \mathbf{g}(\mathbf{x})$
- Bemeneti x_i ($i = 1, \dots, m$) mennyiségek (együttes) vsz. eloszlás függvényei is ismertek: $F_i(x_i)$ ($F(\mathbf{x})$)
- Előállítunk az ismert $F_i(x_i)$ eloszlások ($F(\mathbf{x})$) alapján véletlenszerűen egy lehetséges \mathbf{x} bemenetet és meghatározzuk a \mathbf{g} függvény alapján az y_k ($k = 1, \dots, n$) kimeneteket
- Monte Carlo: Az eljárást sokszor (N -szer) megismételve az y_k kimenetek mindegyikéből N elemű mintát kapunk
- A kimeneti mennyiségek tapasztalati eloszlásait meghatározzuk
- Az eloszlások segítségével az y_k kimenetek legjellemzőbb értékeit és bizonytalanságait kiszámítjuk

Monte Carlo módszerek alkalmazása a mérési bizonytalanság meghatározására

- A GUM Supplement 1: „Propagation of distributions using a Monte Carlo method” 5.1.1
 - a) modell felállítása
 1. a mérendő mennyiség, Y definiálása
 2. az $\mathbf{X} = (X_1, X_2, \dots, X_N)^T$ bemeneti mennyiségek meghatározása, amiktől Y függ
 3. az \mathbf{X} -et és Y -t összekapcsoló modell megalkotása
 4. a meglevő ismeretek alapján X_i -k eloszlásfüggvényeinek (Gauss, egyenletes, háromszög, stb.) megadása, illetve nem független X_i -k együttes eloszlásfüggvényeinek a megadása
 - b) terjedés
 - c) összefoglaló statisztikák készítése Y eloszlásfüggvényéről

Monte Carlo módszerek alkalmazása a mérési bizonytalanság meghatározására

- A GUM Supplement 1: „Propagation of distributions using a Monte Carlo method” 5.1.1
 - a) modell felállítása
 - b) terjedés
 1. az X_i -k eloszlásfüggvényeinek terjedése a modellen keresztül, hogy megkapjuk Y eloszlásfüggvényét
 - c) összefoglaló statisztikák készítése Y eloszlásfüggvényéről
 1. az Y várható értéke lesz a mennyiség y becslése (nem minden alkalmazás számára megfelelő)
 2. az Y standard bizonytalansága lesz az y mennyiség $u(y)$ standard bizonytalansága (Cauchy eloszlás esetén nem létezik)
 3. megbízhatósági tartomány készítése, mely Y -t előírt megbízhatósági valószínűséggel tartalmazza

Eloszlásfüggvények terjedése

- a mérendő mennyiség, Y eloszlásfüggvénye:


$$G_Y(\eta) = \int_{-\infty}^{\eta} g_Y(z) dz$$

- a sűrűségfüggvény formális definíciója (δ a Dirac delta):

$$g_Y(\eta) = \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} g_X(\xi) \delta(\eta - f(\xi)) d\xi_N \cdots d\xi_1$$


- analitikusan az integrálás nem végrehajtható, helyette Monte Carlo számításra (MCM) van szükség

Eloszlásfüggvények terjedése





Az eloszlások terjedésének illusztrációja $N = 3$ független bemeneti mennyiségre

Monte Carlo számítás





MCM példa

$$\eta = \xi_1 + \xi_2 + \xi_3$$



$$\eta = f(\xi_1, \xi_2, \xi_3)$$



Irodalom

- Steiner F. (1990): 5.1.3 pont
- Barabás B. (2010): Extrémérték-elmélet BME TTK
- Brodin E. (2006): A Non-mathematical Introduction to Statistics of Extremes NFT 3/2006
- Friederichs P. (2007): An Introduction to Extreme Value Theory University of Bonn, COPS Summer School