

ÚJABB STATISZTIKAI VIZSGÁLATOK
AZ ORNSTEIN-UHLENBECK FOLYAMATRÓL
II. SZIMULÁCIÓ

FEGYVERNEKI SÁNDOR

A dolgozatban a stacionárius Gauss-Markov(Ornstein-Uhlenbeck) folyamat paramétereinek együttes vizsgálatával foglalkozom. Ezen folyamat esetén számos probléma adódik a maximum-likelihood becslések eloszlásának vizsgálatával és a paraméterekre adandó konfidenciaintervallumok meghatározásával, ha a csillapítási tényező tart nullához. A cikk célja annak bemutatása, hogy a „közel nemstacionárius” esetben a csillapítási tényezőre adott konfidencia-intervallum baloldali végpontja pozitív valószínűséggel a nulla.

1. Bevezetés

A dolgozatban a

$$d\xi(t) = -\lambda\xi(t)dt + \sigma_w dw(t), \quad (E(\xi(t)) = E(w(t)) = 0)$$

sztochasztikus differenciálegyenlet szimulációs vizsgálatával foglalkozom, ahol $\lambda > 0$ és $\sigma_w > 0$. Továbbá a $\xi(t_0)$ normális eloszlású és független a $w(t)$ standard Wiener-folyamattól, ha $t > t_0$. Ezek a vizsgálatok a [7] cikkben leírt háttérre támaszkodnak, azt fejlesztem tovább. Ezenkívül az eredményeket szimuláció alkalmazásával is szemléletessé teszem.

Ezen dolgozat a [7] (I. rész) közvetlen folytatása és felépítése a következő: A szimuláció leírása. A maximum-likelihood becslések meghatározására megadott numerikus módszerek összehasonlítása. A közelítő modell esetén alkalmazott robusztus technika rövid leírása. A szimulációs eredmények összefoglalása, a tapasztalatok leírása, és annak bemutatása, hogy a „közel nemstacionárius” esetben a csillapítási tényezőre adott konfidencia-intervallum baloldali végpontja pozitív valószínűséggel a nulla.

A szimulációkban keletkezett adatokból, becslési eredményekből összesítő táblázatokat és grafikonokat készítettem, amelyek segítségével jobban látható a „közel

nemstacionárius” eset, illetve az összes paraméter együttes becslésének különlegessége. Először felhívom a figyelmet néhány egyszerű tényre a $\kappa \rightarrow 0$ esetben. Ezenkívül leírom azokat a jelöléseket, amelyek előfordulnak a táblázatokban és ábrákban. Bemutatom a lényeges különbséget az ismert és ismeretlen várható érték (az m paraméter) eset között. Jól látható, hogy miért ad jó közelítést a λ_{01} becslés $\lambda \rightarrow 0$ esetén, ha m ismert, és milyen problémák adódnak, ha m ismeretlen.

2. A szimuláció

A

$$t = t'T, \quad \xi = \xi' \sigma_w \sqrt{T}$$

leképezéssel az általános feladatot a $T = 1$ és $\sigma_w = 1$ esetre vezethetjük vissza, amikor is $\lambda' = \lambda T = \kappa$, azaz az időegység megválasztásától függetlenül ismert m esetén a folyamat realizációi egyetlen paraméterrel, a κ -val vannak jellemezve.

Ez a transzformáció a vizsgálatunkat lényegesen nem befolyásolja, hiszen a maximum-likelihood becslés meghatározásakor ([7]-ben (14)) a λ meghatározása esetén az m is adódik ([7]-ben (13)). Így vizsgálatunkat szimuláció során a λ becsléseinek meghatározására összpontosítjuk. Mivel a [7]-beli (14) egyenletben csak az m paramétertől független statisztikák fordulnak elő, ezért az egyszerűség kedvéért legyen $m = 0$ a szimuláció során. A vizsgálatok során az m értékét ismeretlennek tekintjük.

Legyen n a $[0, 1]$ intervallum beosztásainak a száma, és vezessük be a következő jelöléseket:

$$\xi \left(\frac{i}{n} \right) = \xi_i, \quad i = 0, 1, \dots, n.$$

$$\rho = e^{-\frac{\lambda}{n}}, \quad \sigma^2 = \frac{1 - \rho^2}{2\lambda}.$$

Ekkor a szimuláció algoritmus:

$$u = \Phi^{-1}(\text{random}), \quad \xi_0 = \frac{u}{\sqrt{2\lambda}},$$

$$\xi_{i+1} = \rho \xi_i + \sigma \Phi^{-1}(\text{random}), \quad i = 0, 1, \dots, n-1,$$

ahol a Φ^{-1} a standard normális eloszlásfüggvény inverzét jelöli, és a *random* függvény egy pszeudóvéletlen számokat előállító generátor a $[0, 1)$ intervallumon egyenletes eloszlásra.

A maximum-likelihood egyenletekben megjelenő statisztikák szimulációs megfelelői a következők:

$$\begin{aligned} m_1 &= \frac{\xi_0 + \xi_n}{2}, \\ m_2 &= \frac{\sum_{k=0}^n \xi_k}{n+1}, \\ s_1^2 &= \frac{(\xi_n - \xi_0)^2}{4}, \\ s_2^2 &= \frac{\sum_{k=0}^n (\xi_k - m_2)^2}{n+1}, \\ s_{01}^2 &= \frac{\xi_0^2 + \xi_n^2}{2}. \end{aligned}$$

A szakirodalomban a maximum-likelihood becsléseken kívül a következő becsléseket szokás vizsgálni:

$$\begin{aligned} \lambda_1 &= \frac{0,5}{s_1^2}, \\ \lambda_2 &= \frac{0,5}{s_2^2}, \\ \lambda_{01} &= \frac{0,5}{s_{01}^2}. \end{aligned}$$

Megjegyzés. Ha egy jelölésben megjelenik a 0, akkor feltételezzük, hogy az m paraméter ismert, egyébként ismeretlen.

3. A numerikus megoldási módszerek összehasonlítása

A [7] cikkben a (11-12) egyenletrendszer megoldására javasoltuk a Newton-módszert, illetve az ún. „gyökös” módszert. A következő három táblázatban összefoglaltuk a két módszert jellemző – az iterációk számára és a végrehajtás idejére vonatkozó – adatokat. A táblázatokban 100 darab gyökmeghatározás átlagos adatai szerepelnek. Az iterációk leállítására 10^{-3} , 10^{-6} , illetve 10^{-9} hibakorlátnál történt. Az idő meghatározásához az algoritmusokat 10^5 alkalommal hajtottuk végre, így az idő mértékegysége 10^{-5} mp. Rövidítések: Gy.it.szám – a gyökös módszer átlagos iteráció száma, Gy.idő – a gyökös módszer átlagos ideje, N.it.szám – a Newton-módszer átlagos iteráció száma, N.idő – a Newton-módszer átlagos ideje.

A 3.4. táblázat azt mutatja, hogy $\lambda = 1$ esetén hogyan változnak az előbbi táblázatok mutatói, ha a minta nagysága változik. Jól látható, hogy nem lenne érdemes a vizsgálatainkat nagy mintaelemszámra elvégezni, hiszen az átlagos mutatók nagyságrendje nem változik.

Megjegyzés. A két módszer által adott gyökök eltérése mindig kisebb volt a hibakorlát felénél, így erre vonatkozóan nincs adat a táblázatokban. Miután a szimulációs eredmények azt mutatják, hogy a számítógépes implementációm esetén az ún. „gyökös” módszer gyorsabb, így a vizsgálatokban ezt használtam.

3.1. táblázat. A hibakorlát 10^{-3} .

λ	Gy.it.szám	Gy.idő	N.it.szám	N.idő
0,000000001	3,40	0,405	9,04	1,335
0,000010000	3,64	0,435	6,85	1,162
0,010000000	3,38	0,406	8,21	1,271
0,100000000	3,36	0,404	8,41	1,284
0,500000000	3,35	0,407	8,50	1,287
1,000000000	3,26	0,401	8,60	1,293
2,000000000	3,42	0,416	9,04	1,328
5,000000000	3,15	0,385	10,81	1,459
10,000000000	2,84	0,346	12,10	1,559
50,000000000	2,23	0,280	13,00	1,625
100,000000000	2,01	0,257	13,00	1,626
500,000000000	2,00	0,258	13,00	1,626
1000,000000000	2,00	0,260	13,00	1,625

3.2. táblázat. A hibakorlát 10^{-6} .

λ	Gy.it.szám	Gy.idő	N.it.szám	N.idő
0,000000001	4,55	0,525	10,74	1,461
0,000010000	5,64	0,648	7,64	1,219
0,010000000	4,95	0,575	9,13	1,337
0,100000000	5,05	0,588	9,39	1,355
0,500000000	5,05	0,588	9,16	1,337
1,000000000	4,78	0,558	9,55	1,370
2,000000000	5,16	0,603	9,90	1,396
5,000000000	4,80	0,563	11,66	1,525
10,000000000	4,01	0,479	13,06	1,627
50,000000000	3,26	0,396	13,59	1,672
100,000000000	2,97	0,363	14,00	1,699
500,000000000	2,85	0,350	14,00	1,700
1000,000000000	2,65	0,324	14,00	1,700

3.3. táblázat. A hibakorlát 10^{-9} .

λ	Gy.it.szám	Gy.idő	N.it.szám	N.idő
0,000000001	5,86	0,670	11,37	1,511
0,000010000	7,69	0,872	8,15	1,261
0,010000000	6,83	0,778	9,50	1,363
0,100000000	6,47	0,742	10,16	1,410
0,500000000	6,84	0,786	9,93	1,396
1,000000000	6,57	0,752	10,62	1,448
2,000000000	7,12	0,815	10,64	1,447
5,000000000	6,21	0,719	12,28	1,571
10,000000000	5,34	0,624	13,69	1,676
50,000000000	4,02	0,478	14,00	1,699
100,000000000	3,61	0,434	14,00	1,701
500,000000000	3,12	0,380	14,00	1,699
1000,000000000	3,00	0,367	14,00	1,698

3.4. táblázat.

Mintaszám	Gy.it.szám	Gy.idő	N.it.szám	N.idő
10	6,60	0,754	9,30	1,350
50	6,48	0,742	9,78	1,382
100	6,57	0,752	10,62	1,448
500	6,69	0,765	9,83	1,390
1000	6,75	0,774	10,07	1,406
5000	6,90	0,789	10,02	1,403

4. A modelleloszlás szerinti robusztus becslések

Ebben a szakaszban a témában elért eredményeimet foglaltam össze (l.[6]). Megadom az általam modelleloszlás szerinti robusztus becslésnek nevezett módszert és annak tulajdonságait.

Legyen adott egy $\xi_1, \xi_2, \dots, \xi_n$ véletlen minta, amelynek elemei függetlenek, azonos eloszlásúak F eloszlásfüggvénnyel. Ezenkívül tudjuk, hogy a mintaelemek eloszlása az F_0 eloszlásfüggvénnyel reprezentált eloszlástípusba tartozik.

A feladat az, hogy a mintából megbecsüljük a μ, σ értékeket úgy, hogy az

$$F_0\left(\frac{x-\mu}{\sigma}\right) = F(x)$$

egyenlőség teljesüljön.

Legyen a hely- és a skálaparaméterre felírt egyenletrendszer a következő:

$$\sum_{i=1}^n \left(F_0\left(\frac{\xi_i - \mu}{\sigma}\right) - \frac{1}{2} \right) = 0, \quad (1)$$

$$\sum_{i=1}^n \left(\left(F_0\left(\frac{\xi_i - \mu}{\sigma}\right) - \frac{1}{2} \right)^2 - \frac{1}{12} \right) = 0. \quad (2)$$

Tehát $\psi(x) = F_0(x) - 0,5$, és $\chi(x) = \psi^2(x) - \frac{1}{12}$. A jelölés a robusztus statisztikában szokásos (l. [9], [10], [12]).

4.1. Definíció. A (4.1-2) egyenletrendszer létező megoldását (jelölje azt T_n és s_n) a hely-, illetve skálaparaméter modelleloszlás szerinti becslésének (röviden (PT)-becslés) nevezzük.

4.1. ÁLLÍTÁS. Ha az F_0 eloszlásfüggvény differenciálható, szigorúan monoton növekvő és $F_0(0) = 0,5$, akkor a (4.1-2) egyenletrendszer megoldása egyértelműen létezik úgy, hogy $s_n > 0$. Továbbá, a (PT)-becslés B-, V- és kvalitatív robusztus, amelyre a katasztrófa pontok

$$\varepsilon^*(T_n) = \frac{\delta}{1+\delta} = 0,5, \quad \text{ahol} \quad \delta = \min \left\{ -\frac{\psi(-\infty)}{\psi(+\infty)}, -\frac{\psi(+\infty)}{\psi(-\infty)} \right\}$$

és

$$\varepsilon^*(s_n) = \frac{-\chi(0)}{\chi(-\infty) - \chi(0)} = \frac{1}{3}.$$

Ezenkívül (T_n, s_n) együttes eloszlása aszimptotikusan normális, azaz

$$\sqrt{n}((T_n, s_n) - (\mu, \sigma)) \xrightarrow{d} N(0, \Sigma),$$

ahol a kovariancia mátrix $\Sigma = C^{-1}S[C^{-1}]^T$.

$$C = \begin{pmatrix} E\left(\frac{\partial}{\partial \mu} \psi\left(\frac{\xi - \mu}{\sigma}\right)\right) & E\left(\frac{\partial}{\partial \sigma} \psi\left(\frac{\xi - \mu}{\sigma}\right)\right) \\ E\left(\frac{\partial}{\partial \mu} \chi\left(\frac{\xi - \mu}{\sigma}\right)\right) & E\left(\frac{\partial}{\partial \sigma} \chi\left(\frac{\xi - \mu}{\sigma}\right)\right) \end{pmatrix},$$

$$S = \begin{pmatrix} E(\psi^2(\eta)) & E(\psi(\eta)\chi(\eta)) \\ E(\psi(\eta)\chi(\eta)) & E(\chi^2(\eta)) \end{pmatrix} = \begin{pmatrix} \frac{1}{12} & 0 \\ 0 & \frac{1}{180} \end{pmatrix}$$

ahol az η F_0 eloszlásfüggvényű.

Az állítás bizonyítását Huber [10] alapján készítettem.

A robusztus becslések többségét a szimmetrikus esetekre (a feltételezett sűrűségfüggvény szimmetrikus a helyparaméterre), illetve a normális eloszlás közelségére dolgozták ki. Az általam megadott módszer minden olyan esetben jól alkalmazható egy eloszlástípus hely- és skálaparaméterének meghatározására, amikor az eloszlástípus reprezentálható szigorúan monoton eloszlásfüggvénnyel, illetve jól megközelíthető ilyennel. A [6] cikkben számos alkalmazás mellett az egyenletrendszer megoldásához szükséges algoritmust is megadtam. Ezt használtam a szimulációk során a (PT)-becslések, illetve a nemcentrális χ_1^2 -eloszlás paramétereinek maximum-likelihood becslésének a meghatározására is.

5. Aszimptotika, jelölések, táblázatok, konfidencia-intervallum

A szimuláció segítségével a következő kérdésköröket próbáljuk megvizsgálni.

1. Ismert m várható érték esetén a λ maximum-likelihood becslése, mely paramétertartományban lesz közel χ_1^2 -, illetve normális eloszlású; és mikor kell használnunk az ún. egzakt eloszlásfüggvény táblázatokat (l. Arató, Benczúr [2], [3], Arató, Kuki, Szabó [4])? Továbbá, a maximum-likelihood becslés helyett mikor használható egyszerűbben meghatározható becslés?
2. Ha mind az m , mind a λ paraméter ismeretlen, akkor mit tudunk mondani az elégséges statisztikák, a maximum-likelihood becslések és a hozzájuk kötődő néhány – a szakirodalomban előforduló – egyszerű becslésről, különös tekintettel arra az esetre, amikor $\lambda \rightarrow 0$.
3. Az előző kérdéskörhöz kapcsolódik az a probléma, hogy mit tudunk mondani a paraméterekre felírt konfidencia-intervallumokról. Hogyan lehet érzékelteni a $\lambda \rightarrow 0$ eset különlegességét, ha mind a három paraméter ismeretlen?

Az eddigi elméleti eredmények és szimulációs vizsgálatok alapján ismert, hogy még egyparaméteres esetben is vagy az aszimptotikus eloszlást ismerjük, vagy megfelelő számítógépes háttérrel megtudjuk adni az egzakt eloszlás közelítését. Továbbá néhány esetben az átlag, illetve a tapasztalati szórásnégyzet nem használható, mert nem létezik a várható érték. Ez indokolja, hogy a klasszikus módszerek (átlag, szórásnégyzet, maximum-likelihood becslés, kvantilis becslések) mellett más módszereket is alkalmazzunk, amelyek kevésbé érzékenyek az ún. kiugró értékekre, illetve arra, hogy a feltételezett modell csak közelíti a ténylegest. Ezért felhasználjuk a 4. szakaszban ismertetett (PT)-becsléseket. Előnye, hogy robusztus, a vizsgált esetekben egyértelműen léteznek a becslések, s a megadott algoritmussal rögtön meg is határozhatók. Jól kezeli a nemcentrális χ_1^2 -eloszlás paramétereinek a meghatározását. Sőt a maximum-likelihood becslés is könnyen meghatározható

a (PT)-becslésekhez megadott numerikus algoritmussal. A módszer stabilitásán kívül az is fontos volt, hogy a számolási és kerekítési hibákra kevésbé érzékeny. Ez különösen fontos az aszimptotikus esetben.

A szimuláció során tapasztaltak leírásához, illetve az elkészített táblázatok megértéséhez szükség van a következő jelölések, illetve jelölési alapelvek ismertetésére.

$\bar{\vartheta}$ – a ϑ statisztika átlaga.

σ_{ϑ}^* – a ϑ statisztika korrigált tapasztalati szórása.

$\hat{\mu}_{\vartheta}(F)$ – a ϑ statisztikára vonatkozó helyparaméter maximum-likelihood becslése, ha a feltételezett eloszlástípus F .

$\hat{\sigma}_{\vartheta}(F)$ – a ϑ statisztikára vonatkozó skálaparaméter maximum-likelihood becslése, ha a feltételezett eloszlástípus F .

$T_{\vartheta}(F)$ – a ϑ statisztikára vonatkozó helyparaméter (PT)-becslése, ha a feltételezett eloszlástípus F .

$s_{\vartheta}(F)$ – a ϑ statisztikára vonatkozó skálaparaméter (PT)-becslése, ha a feltételezett eloszlástípus F .

Φ – a standard normális eloszlásfüggvény.

χ_1 – a χ_1^2 eloszlásfüggvény.

χ_1' – a nemcentrális χ_1^2 eloszlásfüggvény.

A táblázatokban lévő eredmények csak egy kis szeletét mutatják meg az összes szimulációnak, és csak néhány szempont szerinti gígyűjtést jelenítettem meg.

A táblázatok rövid leírása:

Az 5.1–4. táblázatok a λ maximum-likelihood becslésének, a λ_1 , a λ_2 és a λ_{01} statisztikák eloszlásának a kvantilisbecsléseit tartalmazzák különböző λ paraméter értékeket feltételezve. A táblázatokban

$$P(\vartheta < z_{\lambda,p}) = p$$

értékek becslése található. A szimuláció során a $[0, 1]$ intervallum beosztásainak száma $n = 100$. Ezután 1000 elemű rendezett minta készül a kvantilis becslésére, majd mindez 100-szor megismétlődik, s ezek átlaga adja a táblázatokban szereplő számokat. A hibakorlát pedig $\varepsilon = 10^{-10}$.

Megjegyzés. Ha a beosztások számát és az egyes kvantilisekre vonatkozó mintaelemszámot növeltem, akkor a tendenciák nem változtak, viszont gyorsan nőtt a futási idő.

Az 5.6–12. táblázatok az m , m_1 , m_2 , λ , λ_1 , λ_2 és λ_{01} paraméterek becslésének, illetve statisztikák eloszlásának megfelelő paraméterek becslésének összegzését

tartalmazzák a fenti jelöléseket követve. Ezen táblázatok készítésekor a beosztások száma $n = 1000$, a mintaelemek száma szintén 1000 és a hibakorlát 10^{-10} .

A statisztikák eloszlásának leírását, illetve a megfelelő paraméterbecslések jellemzését kezdjük az egyszerűbb esetekkel.

Az 5.7. táblázat alapján is ugyanaz látható, mint amit az elméletből tudunk, hogy kis λ esetén az m paraméter becsléseinek szórásnégyzete tart $+\infty$ -hez. Viszont a ([7], 55. oldal) sorfejtésből jól látható, hogy

$$\lim_{\lambda \rightarrow 0} E((m_1 - m_2)^2) = \frac{1}{12},$$

azaz véges és a határeloszlása megadható ([7]-ben 3.1. Állítás) alapján.

Ha csak a csillapítási tényező ismeretlen, akkor ismert, hogy $\lambda \rightarrow 0$ esetén az elégséges statisztikák leírásához szükséges a χ_1^2 -eloszlás. Hiszen a karakterisztikus függvényből az is látható, hogy $\lambda \rightarrow 0$ esetén s_{01}^2 és s_{02}^2 aszimptotikusan ekvivalensek, és $2\lambda s_{02}^2$ aszimptotikusan χ_1^2 , ha $\lambda \rightarrow 0$. Már Striebel [15] alapján ismert volt, hogy „kis” λ esetén λ_{01} megfelelő becslés a λ paraméterre. A λ_{01} -re vonatkozó szimulációs eredmények (l. 5.4., 5.6. és 5.12. táblázatok) alátámasztják, hogy az eloszlás aszimptotikusan reciproka χ_1^2 -eloszlás. A ([7], 3.1. Állítás) felbontás és a ([7], 52. oldal) alapján pedig látható, hogy az átlag és a korrigált tapasztalati szórás nem adhat jó eredményt. Ez azt mutatja, hogy az ezekből adódó konfidencia-intervallum rosszabb, mint a reciproka χ_1^2 -eloszlás feltételezéséből kapott.

Megjegyzés. A [7]-beli 3.1. Állításban szereplő mennyiségek reciprokának közelítő táblázata és a sorfejtések –

$$\sigma^2 = \frac{1}{2\lambda} \quad \text{és} \quad \rho = e^{-\lambda}$$

– megtalálhatóak az 5.5. táblázatban, illetve ([7], 55. oldal) formulákban.

Vizsgáljuk meg mennyiben különbözik ettől az az eset, amikor az m és a λ is ismeretlen. Alkalmazzuk a [7] 3. szakaszában leírtakat a szimuláció során vizsgált esetekben, azaz

$$\sigma_w = 1, \quad T = 1, \quad \xi_1 = \xi(0), \quad \xi_2 = \xi(T), \quad \sigma^2 = \frac{1}{2\lambda}, \quad \text{és} \quad \rho = e^{-\lambda}.$$

Hasonlítsuk össze ilyen értékek mellett a $\varphi(t_1, t_2)$ karakterisztikus függvényt az elégséges statisztikák $\psi(t_1, t_2, t_3, t_4)$ karakterisztikus függvényéből (l. [1], 185. oldal) adódó függvényel, amikor $t_3 = t_4 = 0$. Ekkor

$$\Lambda = \lambda \quad \text{és} \quad \psi(t_2, 0) = e^\lambda (2\lambda)^2 \left[\left(1 - it_2 \frac{1}{2\lambda}\right)^2 - i^2 t_2^2 \frac{1}{(2\lambda)^2} e^{-2\lambda} \right].$$

Ezeket felhasználva

$$\psi(t_1, t_2, 0, 0) = \frac{1}{\sqrt{(1 - it_2 \frac{1}{2\lambda})^2 + t_2^2 (\frac{1}{2\lambda})^2 e^{-2\lambda}}} \exp \left\{ -\frac{t_1^2 \frac{1}{2\lambda} (1 + e^\lambda)}{4e^\lambda (1 - it_2 \frac{1}{2\lambda}) (1 + e^{-\lambda})} \right\},$$

ami pontosan megegyezik a $\varphi(t_1, t_2)$ -ből adódó formulával.

Tehát a szimulációnál az s_1^2 statisztika χ_1^2 -eloszlású. Továbbá a várható érték

$$\frac{\sigma^2(1 - \rho)}{2} = \frac{1 - e^{-\lambda}}{4\lambda}$$

és

$$\lim_{\lambda \rightarrow 0} E(s_1^2) = \lim_{\lambda \rightarrow 0} \frac{1 - e^{-\lambda}}{4\lambda} = \frac{1}{4}.$$

Tehát λ_1 reciprok χ_1^2 -eloszlású, amelynek nem létezik a várható értéke (és így a szórása sem). Ez jól látható az 5.8-9. táblázatok alapján is.

Ezenkívül

$$\lim_{\lambda \rightarrow 0} \frac{2\lambda}{1 - e^{-\lambda}} = 2.$$

Az 5.1. és az 5.2. táblázatok segítségével összehasonlíthatjuk a kvantiliseket. A reciprok χ_1^2 kvantilisei, ha a skálaparaméter 2, azaz a ([7], 52. oldal) formula alapján $\sigma = 2$ esetén.

(5.1)

p	0,01	0,05	0,1	0,5	0,9	0,95	0,99
$F^{-1}(p)$	0,3014	0,5206	0,739	4,396	126,6	508,6	12731,7

A λ_1 statisztikáról összegzésül elmondhatjuk, hogy reciprok χ_1^2 -eloszlású, és a $\lambda < 0,1$ esetek között a táblázatok alapján nem lehet különbséget tenni.

Az Arató [1], Arató, Benczúr [2], [3] munkák részletesen foglalkoznak a konfidencia-intervallum készítésével az m , illetve λ paraméterre. A következő részben azt mutatjuk be, hogy adott p valószínűség mellett mikor nem tudunk megadni olyan intervallumot, amelynek alsó határa különbözik a nullától, és benne van a λ valódi paraméter.

Ha mindkét paraméter ismeretlen, akkor jól látható a kvantilis becslések alapján, hogy kis λ paraméter esetén – a p valószínűség értékétől függően – nem tudunk a szimuláció segítségével nullától különböző alsó határú konfidencia-intervallumot adni (l. 5.1–3. táblázat). Például rögtön látható, hogy ha a szimulációnál $\lambda < 0,1$, akkor

$$\lambda < z_{\lambda, 0,01},$$

azaz a kvantilis becslések alapján kapott konfidencia-intervallumban nincs benne a paraméter.

Megvizsgáljuk, hogy ez mennyire adódhat az elméleti viselkedésből, illetve a számolási hibákból és a szimuláció „tökéletlenségéből”.

Mivel $\hat{\lambda}$ és λ_2 becslések eloszlását nem tudtuk pontosan meghatározni, ezért kezdjük a λ_1 esettel. Az eloszlásfüggvény (l. [7], 52. oldal)

$$F(x) = 2 - 2\Phi\left(\sqrt{\frac{a}{x}}\right), \quad \text{ha } x > 0,$$

ahol

$$a = \frac{2\lambda}{1 - e^{-\lambda}}.$$

Mivel

$$\lim_{\lambda \rightarrow 0} a = 2,$$

így λ_1 kvantiliseit megadhatjuk $\lambda \rightarrow 0$ esetén (l. (5.1)). Látható, hogy a kvantilis becslések két értékes jegyre közelítik a kvantiliseket.

Ezután pontosan meghatározzuk, hogy rögzített p valószínűség esetén mely λ értékekre nincs benne az eloszlás kvantilisei alapján adott konfidencia-intervallumban.

Ha η reciprok χ_1^2 -eloszlású, akkor legyen x_p olyan, hogy

$$P(\eta < x_p) = p.$$

Tehát a

$$p = 2 - 2\Phi\left(\sqrt{\frac{1}{x_p}}\right),$$

azaz

$$x_p = \frac{1}{\left[\Phi^{-1}\left(1 - \frac{p}{2}\right)\right]^2}.$$

A λ_1 kvantiliseire használjuk a $z_{\lambda_1, p}$ jelölést, azaz

$$P(\lambda_1 < z_{\lambda_1, p}) = p.$$

Kérdés, mikor teljesül, hogy

$$\lambda < z_{\lambda_1, p},$$

azaz

$$\lambda < \frac{2\lambda}{1 - e^{-\lambda}} x_p = \frac{2\lambda}{1 - e^{-\lambda}} \frac{1}{\left[\Phi^{-1}\left(1 - \frac{p}{2}\right)\right]^2}.$$

Jelölje u_p azt a λ értéket, amikor az előző egyenlőtlenségben egyenlőség teljesül, azaz

$$u_p = -\ln\left(1 - \frac{1}{\left[\Phi^{-1}\left(1 - \frac{p}{2}\right)\right]^2}\right).$$

Az egyenlet megoldása közben adódik, hogy csak

$$x_p < 0,5$$

esetén van ilyen λ , azaz ha

$$p < 0,157299.$$

A következő táblázat néhány ilyen értéket tartalmaz.

p	0,01	0,05	0,1	0,15	0,157299	0,16	0,20
x_p	0,1507	0,2603	0,3696	0,4825	0,4999995	0,5065	0,6088
u_p	0,3587	0,7353	1,344	3,356	13,8155	–	–

A λ_1 statisztika eloszlása alapján elkészített u_p értékeket szemléletesen jól láthatjuk az 1. ábrán. Továbbá a 2–4. ábrák (az 5.1–3. táblázat) pedig a megfelelő kvantilis becslések alapján készültek. Az ábrák mindegyike tartalmazza a $p = 0,01, 0,05, 0,1, 0,5$ eseteket kiegészítve az $f(\lambda) = \lambda$ egyenessel, s így a metszéspontok megadják, hogy mely p érték esetén milyen λ -ra nincs a konfidencia-intervallumnak nullától különböző pozitív alsó határa. A 1–4. ábrák és az (5.2)-ben szereplő közelítő értékek azt mutatják, hogy az alsó határ a λ_1 alapján becsülhető a legtovább, azaz adott p valószínűsége ekkor a legkisebb az u_p értéke.

(5.2)

p	0,01	0,05	0,1
$u_{p,\hat{\lambda}}$	0,4483	1,0941	2,0571
u_{p,λ_1}	0,3527	0,7325	1,3521
u_{p,λ_2}	0,9013	1,8399	3,0750

Figyeljük meg, hogy a becsült u_{p,λ_1} értékek milyen jól közelítik a megfelelő elméleti értéket.

Megjegyzés. Az 1. ábra ezenkívül tartalmazza a $p = 0,15, 0,16, 0,2$ eseteket. Fontos feladat lehet a közelítő táblázatok megadása a kvantilisekre, hiszen még nagy λ esetén is erősen különböznek a becsült kvantilisek az ismert m esetben kiszámított értékektől (l. [4]).

Néhány további tapasztalat röviden.

1. A $\hat{\lambda}$ és λ_2 statisztikákról az 5.11. táblázat alapján: a táblázat a nemcentrális χ_1^2 -eloszlás alapján adódó (PT)-becsléseket és a maximum-likelihood becsléseket adja meg. Látható, hogy nincs lényeges különbség a kétféle becslés között. Továbbá a helyparaméter négyzete jól közelíti a $z_{\lambda,0,5}$ értékét (5.1–2. táblázat), illetve megfigyelhető, hogy a skálaparaméter értéke gyakorlatilag a (0,7,0,9) intervallumban mozog. Gondoljuk végig, mit is jelent itt a skálaparaméter, és hogyan kaphatunk belőle konfidencia-intervallumot!
2. A táblázatok értékei – $\lambda \geq 100$ esetekben – jól mutatják, hogy az [1] könyvben leírt és jellemzett aszimptotikus normalitás teljesül, így a normális eloszlás (t -eloszlás) jól használható konfidencia-intervallumok készítésére.
3. A becslések szimulálásakor kiderült, hogy $\lambda \geq 100$ esetén az $n = 1000$ beosztás a $[0,1]$ intervallumon kevés – a [7]-beli (5) formulával leírt módon – a σ_w^2 jó becsléséhez.
4. Az 5.6. és 5.12. táblázat magyarázatot adhat arra, hogy miért lehet jó becslés kis λ esetén λ_{01} .

5.1. táblázat. Kvantilisek λ maximum-likelihood becslésére.

$\lambda \backslash p$	0,01	0,05	0,1	0,5	0,9	0,95	0,99
10^{-9}	0,350	0,644	0,938	3,542	10,233	13,013	19,528
10^{-7}	0,351	0,643	0,944	3,566	10,198	12,948	19,459
10^{-5}	0,349	0,641	0,936	3,556	10,190	12,947	19,198
10^{-3}	0,350	0,644	0,940	3,562	10,178	12,955	19,141
10^{-2}	0,352	0,654	0,947	3,570	10,142	12,910	19,167
0,1	0,37	0,68	0,99	3,64	10,30	13,10	19,52
0,5	0,46	0,83	1,17	3,90	10,30	12,93	18,73
1	0,58	1,05	1,46	4,42	11,28	14,05	20,51
2	0,89	1,52	2,02	5,29	12,27	15,11	21,67
5	2,15	3,21	3,97	8,16	15,86	18,91	25,59
10	4,87	6,55	7,64	13,14	22,06	25,32	32,56
20	11,34	13,90	15,53	23,03	34,06	37,97	46,19
50	32,99	37,98	40,89	53,08	69,04	74,44	85,58
100	71,63	79,56	84,12	103,17	127,51	135,69	151,97
1000	743,96	813,33	853,55	1016,82	1227,21	1298,12	1441,28

5.2. táblázat. Kvantilisek a λ_1 becslésre.

$\lambda \backslash p$	0,01	0,05	0,1	0,5	0,9	0,95	0,99
10^{-9}	0,301	0,527	0,752	4,394	129,78	518,94	14806,46
10^{-7}	0,300	0,523	0,744	4,371	126,96	499,62	13539,76
10^{-5}	0,299	0,522	0,745	4,400	129,80	523,85	13952,99
10^{-3}	0,302	0,524	0,747	4,422	128,61	526,45	12872,36
10^{-2}	0,302	0,526	0,740	4,425	127,80	523,79	14880,24
0,1	0,311	0,544	0,773	4,641	134,62	535,21	14219,93
0,5	0,377	0,661	0,940	5,509	164,25	653,05	16243,21
1	0,473	0,815	1,163	6,879	197,90	827,69	21351,75
2	0,69	1,19	1,70	10,19	292,61	1189,92	32694,29
5	1,49	2,60	3,70	22,25	640,67	2674,51	70891,59
10	2,98	5,22	7,44	43,92	1230,69	4995,15	131177,72
20	6,02	10,50	14,86	87,93	2551,38	10004,34	260795,59

5.3. táblázat. Kvantilisek a λ_2 becslésre.

$\lambda \backslash p$	0,01	0,05	0,1	0,5	0,9	0,95	0,99
10^{-9}	0,661	1,067	1,429	4,146	10,802	13,599	20,114
10^{-7}	0,665	1,063	1,424	4,174	10,747	13,546	20,024
10^{-5}	0,656	1,068	1,422	4,160	10,755	13,520	19,795
10^{-3}	0,662	1,070	1,426	4,174	10,739	13,547	19,661
10^{-2}	0,670	1,084	1,434	4,182	10,720	13,499	19,659
0,1	0,689	1,112	1,479	4,251	10,871	13,691	20,058
0,5	0,797	1,262	1,657	4,528	11,223	13,920	20,484
1	0,927	1,472	1,918	4,965	11,783	14,553	20,963
2	1,25	1,91	2,43	5,74	12,76	15,61	22,18
5	2,46	3,48	4,23	8,47	16,24	19,24	25,98
10	5,04	6,73	7,81	13,30	22,26	25,55	32,86
20	11,40	13,96	15,62	23,14	34,18	38,07	46,33
50	33,04	38,06	40,91	53,13	69,09	74,46	85,65
100	71,69	79,57	84,18	103,17	127,51	135,66	151,94
1000	743,58	812,87	852,98	1017,18	1226,11	1295,18	1435,87

5.4. táblázat. Kvantilisek a λ_{01} becslésre.

$\lambda \backslash p$	0,01	0,05	0,1	0,5	0,9	0,95	0,99
10^{-7}	$1,5 \cdot 10^{-8}$	$2,6 \cdot 10^{-8}$	$3,7 \cdot 10^{-8}$	$2,2 \cdot 10^{-7}$	$6,3 \cdot 10^{-6}$	$2,510 \cdot 10^{-5}$	$6,610 \cdot 10^{-4}$
10^{-5}	$1,5 \cdot 10^{-6}$	$2,6 \cdot 10^{-6}$	$3,7 \cdot 10^{-6}$	$2,2 \cdot 10^{-5}$	$6,3 \cdot 10^{-4}$	0,0025	0,069
10^{-3}	$1,5 \cdot 10^{-4}$	0,000257	0,000368	0,00218	0,062	0,230	2,027
10^{-2}	0,0015	0,0026	0,0037	0,0218	0,475	1,175	7,067
0,1	0,015	0,026	0,038	0,207	2,05	4,40	24,06
0,5	0,089	0,149	0,206	0,83	5,9	12,2	61,1
1	0,197	0,319	0,426	1,50	9,9	20,2	102,1
2	0,421	0,657	0,861	2,90	19,2	39,4	202,4
5	1,07	1,65	2,16	7,20	48,1	99,1	506,4
10	2,14	3,33	4,36	14,42	93,6	189,8	1005,6
20	4,37	6,72	8,72	28,95	191,0	391,9	1997,5

5.5. táblázat.

λ	$\frac{2\lambda}{1+e^{-\lambda}}$	$\frac{2\lambda}{1-e^{-\lambda}}$
10^{-9}	1,000000050 10^{-9}	2,000000000
10^{-7}	1,000000050 10^{-7}	2,000000000
10^{-5}	1,000000050 10^{-5}	2,000000000
10^{-3}	1,000000050 10^{-3}	2,001000100
10^{-2}	0,0100499996	2,010016656
0,1	0,1049958375	2,101666388
0,5	0,6224593310	2,541494082
1	1,462117157	3,163953414
2	3,523188313	4,626070572
5	9,933071491	10,06783655
10	19,99909204	20,00090804
20	39,9999992	40,00000008
50	100,000000	100,000000

5.6. táblázat.

λ	$\hat{\sigma}_\lambda(\chi_1)$	$\hat{\sigma}_{\lambda_1}(\chi_1)$	$\hat{\sigma}_{\lambda_2}(\chi_1)$	$\hat{\sigma}_{\lambda_{01}}(\chi_1)$
10^{-9}	2,135	2,043	2,959	0,000000010
10^{-7}	2,097	1,943	3,016	0,0000000943
10^{-5}	2,164	2,030	3,056	0,0000101994
10^{-3}	2,103	1,974	2,954	0,0009849837
10^{-2}	2,186	2,049	3,113	0,0097313111
0,1	2,193	2,086	3,049	0,1005394659
0,5	2,529	2,575	3,295	0,5116286765
1	2,908	3,041	3,666	0,9929536024
2	3,834	4,316	4,541	1,8876786443
5	7,096	10,096	7,573	5,0552630484
10	12,226	20,800	12,409	10,3854189384
20	22,232	39,762	22,327	20,4598142270
50	51,611	103,782	51,663	50,1775524064
100	101,920	191,048	101,949	99,0642703366
500	502,987	1014,469	502,982	504,0998428836
1000	1002,353	2072,311	1002,350	997,5608938731

5.7. táblázat.

λ	\bar{m}	\bar{m}_1	\bar{m}_2
10^{-9}	-328,184908	-328,193052	-328,179580
10^{-7}	-124,882695	-124,875595	-124,884553
10^{-5}	-12,932015	-12,938207	-12,929066
10^{-3}	0,287774	0,287226	0,292341
10^{-2}	-0,194302	-0,190979	-0,194236
0,1	-0,008145	-0,003466	-0,010227
0,5	0,017906	0,013327	0,022725
1	-0,011508	-0,003422	-0,018271
2	0,022027	0,026912	0,017645
5	0,003324	-0,000577	0,004392
10	0,004124	0,000694	0,004402
20	0,000170	-0,003358	0,000306
50	-0,000588	-0,004599	-0,000430
100	-0,000198	0,000607	-0,000213
500	-0,000046	-0,000067	-0,000046
1000	0,000030	0,000203	0,000030

λ	σ_m^*	$\sigma_{m_1}^*$	$\sigma_{m_2}^*$
10^{-9}	22567,43198	22567,43439	22567,43164
10^{-7}	2297,54239	2297,54520	2297,54032
10^{-5}	221,19998	221,20621	221,20151
10^{-3}	22,53552	22,53430	22,53957
10^{-2}	7,16012	7,15200	7,16812
0,1	2,17374	2,17675	2,18135
0,5	0,88849	0,88528	0,90783
1	0,58614	0,58266	0,61386
2	0,36130	0,38529	0,37737
5	0,16718	0,22233	0,17751
10	0,09211	0,15534	0,09604
20	0,04809	0,10892	0,04914
50	0,01921	0,07162	0,01957
100	0,01002	0,04931	0,01007
500	0,00203	0,02234	0,00203
1000	0,00107	0,01612	0,00107

5.8. táblázat.

λ	$\bar{\lambda}$	$\bar{\lambda}_1$	$\bar{\lambda}_2$
10^{-9}	4,829	1655,893	5,406
10^{-7}	4,805	682,617	5,425
10^{-5}	4,843	1282,959	5,431
10^{-3}	4,740	1323934,599	5,333
10^{-2}	4,785	32208,582	5,438
0,1	4,820	262466,628	5,441
0,5	5,248	375323,002	5,781
1	5,405	1739,684	5,951
2	6,343	5025,983	6,852
5	9,469	108362,612	9,852
10	14,220	41366,754	14,466
20	24,407	609226,748	24,536
50	53,516	32001983,603	53,584
100	104,018	2476187,904	104,059
500	505,153	1098676,658	505,147
1000	1005,018	217378846,779	1005,021

λ	σ_{λ}^*	$\sigma_{\lambda_1}^*$	$\sigma_{\lambda_2}^*$
10^{-9}	4,063	20082,158	4,110
10^{-7}	4,232	10054,182	4,267
10^{-5}	4,257	15152,575	4,262
10^{-3}	4,243	41684574,454	4,304
10^{-2}	4,131	971400,455	4,217
0,1	4,058	7926294,253	4,147
0,5	4,446	11776567,945	4,523
1	4,103	25694,612	4,175
2	4,501	105546,579	4,507
5	5,071	3036950,518	5,156
10	5,647	1204364,109	5,755
20	7,404	13163793,573	7,489
50	10,177	1007331473,865	10,227
100	14,904	45309009,139	14,956
500	33,307	11879326,211	33,300
1000	51,668	6866120869,699	51,719

5.9. táblázat.

λ	$T_\lambda(\Phi)$	$T_{\lambda_1}(\Phi)$	$T_{\lambda_2}(\Phi)$
10^{-9}	4,259	11,174	4,865
10^{-7}	4,147	9,436	4,790
10^{-5}	4,212	9,718	4,812
10^{-3}	4,092	8,954	4,688
10^{-2}	4,189	10,761	4,846
0,1	4,243	10,281	4,867
0,5	4,553	13,203	5,084
1	4,871	15,532	5,416
2	5,742	20,859	6,257
5	8,930	64,093	9,316
10	13,714	97,204	13,952
20	23,997	207,109	24,105
50	53,098	515,933	53,152
100	103,536	996,798	103,569
500	504,262	5593,433	504,230
1000	1004,917	9652,539	1004,914

λ	$s_\lambda(\Phi)$	$s_{\lambda_1}(\Phi)$	$s_{\lambda_2}(\Phi)$
10^{-9}	3,429	15,987	3,545
10^{-7}	3,364	12,721	3,442
10^{-5}	3,372	13,604	3,395
10^{-3}	3,411	12,117	3,461
10^{-2}	3,253	15,249	3,335
0,1	3,333	14,144	3,412
0,5	3,364	18,111	3,435
1	3,455	21,386	3,534
2	3,689	28,462	3,739
5	4,510	93,469	4,595
10	5,227	138,000	5,284
20	7,216	298,171	7,301
50	10,326	714,436	10,356
100	14,951	1445,055	15,057
500	33,339	7703,103	33,348
1000	51,744	12940,382	51,791

5.10. táblázat.

λ	$T_\lambda(\chi_1)$	$T_{\lambda_1}(\chi_1)$	$T_{\lambda_2}(\chi_1)$
10^{-9}	1,197	-0,233	1,671
10^{-7}	1,136	0,034	1,720
10^{-5}	1,171	-0,056	1,780
10^{-3}	1,044	-0,003	1,596
10^{-2}	1,234	-0,183	1,857
0,1	1,217	-0,072	1,773
0,5	1,557	-0,103	2,019
1	1,700	-0,105	2,183
2	2,389	-0,063	2,866
5	4,847	-2,594	5,123
10	9,063	-0,639	9,261
20	17,416	-4,326	17,495
50	43,982	-1,905	44,002
100	90,321	-23,148	90,246
500	473,256	-67,535	473,207
1000	958,745	34,938	958,801

λ	$s_\lambda(\chi_1)$	$s_{\lambda_1}(\chi_1)$	$s_{\lambda_2}(\chi_1)$
10^{-9}	4,366	17,154	4,553
10^{-7}	4,311	14,074	4,407
10^{-5}	4,347	14,738	4,365
10^{-3}	4,326	13,885	4,408
10^{-2}	4,231	16,540	4,289
10^{-2}	4,231	16,540	4,289
0,1	4,330	15,853	4,439
0,5	4,354	20,611	4,460
1	4,543	23,639	4,637
2	4,845	31,804	4,910
5	5,880	99,852	6,034
10	6,710	145,942	6,818
20	9,489	319,960	9,526
50	13,073	780,823	13,112
100	19,066	1519,424	19,196
500	44,327	8638,175	44,338
1000	67,063	14877,598	66,981

5.11. táblázat.

λ	$T_\lambda(\chi'_1)$	$T_{\lambda_2}(\chi'_1)$	$\hat{\mu}_\lambda(\chi'_1)$	$\hat{\mu}_{\lambda_2}(\chi'_1)$
10^{-9}	1,969	2,125	2,016	2,172
10^{-7}	1,944	2,113	2,002	2,174
10^{-5}	1,960	2,121	2,014	2,178
10^{-3}	1,924	2,086	1,982	2,149
10^{-2}	1,960	2,131	2,010	2,185
0,1	1,971	2,133	2,018	2,183
0,5	2,056	2,188	2,117	2,252
1	2,130	2,261	2,173	2,306
2	2,330	2,443	2,378	2,493
5	2,938	3,003	2,975	3,040
10	3,669	3,701	3,701	3,732
20	4,870	4,880	4,884	4,896
50	7,269	7,272	7,282	7,287
100	10,161	10,163	10,173	10,174
500	22,449	22,448	22,463	22,463
1000	31,695	31,695	31,691	31,691

λ	$s_\lambda(\chi'_1)$	$s_{\lambda_2}(\chi'_1)$	$\hat{\sigma}_\lambda(\chi'_1)$	$\hat{\sigma}_{\lambda_2}(\chi'_1)$
10^{-9}	0,877	0,837	0,874	0,828
10^{-7}	0,873	0,818	0,893	0,835
10^{-5}	0,867	0,805	0,886	0,828
10^{-3}	0,891	0,829	0,900	0,843
10^{-2}	0,839	0,788	0,861	0,814
0,1	0,858	0,808	0,864	0,820
0,5	0,830	0,792	0,875	0,841
1	0,823	0,788	0,825	0,794
2	0,804	0,772	0,826	0,796
5	0,771	0,770	0,783	0,778
10	0,713	0,716	0,721	0,730
20	0,744	0,751	0,740	0,746
50	0,709	0,710	0,691	0,694
100	0,735	0,740	0,726	0,728
500	0,742	0,742	0,738	0,737
1000	0,816	0,817	0,815	0,816

5.12. táblázat.

λ	$\bar{\lambda}_{01}$	$T_{\lambda_{01}}(\Phi)$	$T_{\lambda_{01}}(\chi_1)$
10^{-9}	0,0000004520	0,0000000054	-0,0000000001
10^{-7}	0,0000206315	0,0000004505	0,0000000010
10^{-5}	0,0084782052	0,0000515889	-0,0000004706
10^{-3}	0,4909567321	0,0047249365	-0,0000103112
10^{-2}	0,3025506315	0,0542730904	-0,0006022251
0,1	2,9584553512	0,3849289055	0,0169395202
0,5	10,4419325260	1,2900696625	0,1684887499
1	36,2512922522	2,1221856267	0,3786405268
2	14,3667140500	4,0161238720	0,6984491780
5	49,1358446583	10,5848494511	1,8927356790
10	99,6942998767	19,2742707771	4,5206277313
20	125,0085749353	42,8741669071	7,6138634102
50	325,2563957839	100,7337506954	19,5956627102
100	681,3721028164	201,7760313855	36,6146373116
500	3722,7357327552	1145,2344179125	176,2835040404
1000	6485,1994744147	2121,9602044310	362,5585998907

λ	$\sigma_{\lambda_{01}}^*$	$s_{\lambda_{01}}(\Phi)$	$s_{\lambda_{01}}(\chi_1)$
10^{-9}	0,0000053719	0,0000000075	0,0000000084
10^{-7}	0,0001826169	0,0000006132	0,0000006823
10^{-5}	0,1587709934	0,0000722464	0,0000776469
10^{-3}	12,9482311202	0,0065066266	0,0072211597
10^{-2}	1,4535034414	0,0759872892	0,0812450305
0,1	25,0832457455	0,4816070011	0,5534828201
0,5	162,6980331077	1,3592764498	1,7054502079
1	892,1995757717	2,1310300753	2,6408152358
2	106,7566467028	4,0301749968	5,0440818104
5	407,0417578934	10,6076036140	13,3237372965
10	1136,4993741364	17,4635387746	22,6917896410
20	736,1131006574	43,5090030614	52,9080790675
50	1774,9092015925	96,9639194568	125,3218112837
100	4405,5405647631	205,8868058566	253,1602663898
500	21689,9580049764	1182,0954998355	1462,9321527378
1000	33412,7201642518	2178,6256990969	2618,6756658016

Hivatkozások

- [1] ARATÓ M.: *Linear stochastic systems with constant coefficients*. Springer-Verlag, Berlin, 1982
- [2] ARATÓ M. – BENCZÚR A.: *Some new results in the statistical investigation of elementary gaussian processes* in European meeting of statisticians. Budapest, 1972, (69–83.)
- [3] ARATÓ M. – BENCZÚR A.: *Szimulációs eredmények az elemi Gauss-folyamat paramétereinek becslésének eloszlására*. MTA Számítástechnikai Központ Közlemények **8**, 1972, (3–34.)
- [4] ARATÓ M. – KUKI A. – SZABÓ A.: *Exact Distribution of Estimators of Parameters in Ornstein-Uhlenbeck Processes*. Computers Math. Applic. **31**, 1996, (45–54.)
- [5] COX D.D.: *Gaussian likelihood estimation for nearly nonstationary AR(1) processes*. Ann. Stat. **19**, 1991, (1129–1142.)
- [6] FEGYVERNEKI S.: *A special joint estimation of location and scale with applications*. Publ. Univ. of Miskolc, Series D. Natural Sciences, Mathematics, **39**, 1999 (21-27.)
- [7] FEGYVERNEKI S.: *Újabb statisztikai vizsgálatok az Ornstein-Uhlenbeck folyamatról I. Elméleti háttér*. Alkalmazott Matematikai Lapok **23**, 2006, (39-57.)
- [8] GUIRGUIS G. H.: *A rational approximation of the inverse normal probability function*. Comp. Statist. & Data Anal. **11**, 1991, (199-201.)
- [9] HAMPEL F. R. – RONCHETTI E. M. – ROUSSEEUW P. J. – STAHEL W. A.: *Robust statistics: the approach based on influence functions*. Wiley, New York, 1986
- [10] HUBER P. J.: *Robust statistics*. Wiley, New York, 1981
- [11] KÁLOVICS F.: *A continuation method for Chebyshev approximation*. Publ. Univ. of Miskolc, Series D. Natural Sciences **36**, 1995, (33-40.)
- [12] KERÉKFI P.: *A robusztus becslésekről*. Alk. Mat. Lapok **4**, 1978, (327-357.)
- [13] KORMOS J.: *Hypothesis testing for nearly nonstationary autoregressive models*. Computers Math. Applic. **19**, 1990, (75-82.)
- [14] PAP GY. – VAN ZUIJLEN M. C. A.: *Parameter estimation with exact distribution for multidimensional Ornstein-Uhlenbeck processes*. J. Multivariate Analysis **59**, 1996 (153-165.)
- [15] STRIEBEL C. T.: *Densities for stochastic processes*. Ann. Math. Stat. **30**, 1959, (559-667.)

(Beérkezett: 2001. május 15.)

FEGYVERNEKI SÁNDOR
 MISKOLCI EGYETEM, MATEMATIKAI INTÉZET
 3515 MISKOLC, MISKOLC-EGYETEMVÁROS
 matfs@gold.uni-miskolc.hu

SÁNDOR FEGYVERNEKI

An asymptotic analysis is presented for estimation in the three-parameter Ornstein-Uhlenbeck process, where the parameters are the local mean, the drift and the variance. We are interested in the case when the damping parameter (λ , or $\lambda T = \kappa$) is nearly zero. The asymptotic sufficient statistics can be related to noncentral χ_1^2 distribution. The maximum likelihood estimate of the parameter vector is a solution of a rather complicated system of equations. We describe the methods for solving maximum-likelihood equations. Classical and robust estimators are determined for parameters. It is shown that the lower confidence limit of the drift (or damping) parameter is equal to zero with positive probability when it is near to zero.