

6. fejezet

A várható érték becslése

6.1. A legjobb lineáris becslés

X_1, X_2, \dots, X_N független, azonos eloszlású valószínűségi változók véges várható értékkel. Erre az átlag \bar{X} a legjobb lineáris, maximum likelihood stb. becslés. Normális eloszlás esetén az összes becslés között is a legjobb, $D^2\bar{X} = \frac{D^2X_1}{N} = O\left(\frac{1}{N}\right)$. Mi a helyzet stacionárius folyamatra? X_1, X_2, \dots összefüggők! Legyenek X_1, \dots, X_N a stacionárius folyamat megfigyelt értékei, és a várható érték $EX_t = \mu$. Tegyük fel, hogy az $R(t)$ autokovariancia függvény ismert $t = 0, 1, \dots, N - 1$ -re. Keressük a legjobb lineáris becslést, azaz olyan $\alpha_1, \dots, \alpha_N$ -t, amelyre a becslésünk

$$\hat{\mu} = \sum_{t=1}^N \alpha_t X_t$$

alakú, $E\hat{\mu} = \mu$ (torzítatlan) és $D^2\hat{\mu} \rightarrow \min$ (azaz a legjobb). A torzítatlanságból kapjuk, hogy $\sum_{i=1}^N \alpha_t = 1$. Mivel

$$D^2\hat{\mu} = D^2 \left(\sum_{i=1}^N \alpha_t X_t \right) = \sum_{t,s=1}^N \alpha_t \alpha_s R(t-s),$$

így elég ezt minimalizálnunk. A Lagrange-féle multiplikátor módszert hívjuk segítségül: $f = \sum_{t,s=1}^N \alpha_t \alpha_s R(t-s)$ -et kell minimalizálnunk a $\sum_{t=1}^N \alpha_t = 1$ feltétel mellett. A szabály szerint

$$\frac{\partial}{\partial \alpha_i} \left(f - 2\lambda \left(\sum_{t=1}^N \alpha_t - 1 \right) \right) = 2 \sum_{s=1}^N \alpha_s R(t-s) - 2\lambda = 0$$

szükséges feltétel a minimumhoz. Innen

$$\sum_{s=1}^N \alpha_s \cdot R(t-s) = \lambda \quad t = 1, \dots, N. \quad (6.1.1)$$

Jelölés 6.1.1.

$$\Sigma = \begin{pmatrix} R(0) & R(1) & \dots & R(N-1) \\ R(1) & R(0) & \dots & R(N-2) \\ \vdots & \vdots & \ddots & \vdots \\ R(N-1) & R(N-2) & \dots & R(0) \end{pmatrix}, \quad \underline{\alpha} = \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_N \end{pmatrix} \quad \text{és} \quad \underline{1} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

Ezekkel felírva, a torzítatlansági feltétel

$$\sum_{s=1}^N \alpha_s = \underline{1}^\top \cdot \underline{\alpha} = 1, \quad (6.1.2)$$

továbbá ezzel az írásmóddal a 6.1.1 egyenlet

$$\Sigma \cdot \underline{\alpha} = \lambda \cdot \underline{1},$$

Ebből α -t kifejezve majd beírva a feltétel 6.1.2 egyenletébe:

$$\underline{\alpha} = \lambda \cdot \Sigma^{-1} \cdot \underline{\mathbf{1}} \Rightarrow \underline{\mathbf{1}}^\top \cdot \lambda \cdot \Sigma^{-1} \cdot \underline{\mathbf{1}} = 1$$

Ezt λ -ra megoldva kapjuk, hogy

$$\lambda = \frac{1}{\underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{1}}}.$$

Ezek szerint

$$\underline{\alpha} = \frac{\Sigma^{-1} \underline{\mathbf{1}}}{\underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{1}}},$$

tehát végül a legjobb lineáris becslés

$$\hat{\mu} = \frac{\underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{x}}}{\underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{1}}}.$$

Ha X normális, akkor $\hat{\mu}_{ML}$ -t az $f_{X_1, \dots, X_N}(\underline{\mathbf{x}}) = (2\pi)^{-N/2} \cdot |\Sigma|^{-1/2} \cdot \exp \left\{ -\frac{1}{2}(\underline{\mathbf{x}} - \mu \cdot \underline{\mathbf{1}})^\top \Sigma^{-1}(\underline{\mathbf{x}} - \mu \cdot \underline{\mathbf{1}}) \right\}$ alapján adjuk meg¹, azaz elég az exponenciális függvény kitevőjét minimalizálni μ -ben (persze $-\frac{1}{2}$ nélkül értve): $\frac{\partial}{\partial \mu} \left((\underline{\mathbf{x}} - \mu \cdot \underline{\mathbf{1}})^\top \Sigma^{-1}(\underline{\mathbf{x}} - \mu \cdot \underline{\mathbf{1}}) \right) = 2\mu \cdot \underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{1}} - 2 \cdot \underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{x}} = 0$, mivel $(\underline{\mathbf{x}}^\top \Sigma^{-1} \underline{\mathbf{1}})^\top = \underline{\mathbf{1}}^\top \Sigma^{-1} \underline{\mathbf{x}}$, és egy szám transzponáltja önmaga. Innen $\hat{\mu}_{ML}$ ugyanazt adja, mint az előbbi legjobb lineáris becslés.

A legjobb lineáris becslés helyett szokás átlagot venni, ami szintén torzítatlan - azaz $E\bar{X} = \mu$ -, és $D^2\bar{X} = \frac{1}{N^2} \sum_{t,s=0}^{N-1} R(t-s)$ (megj.: $EX_1X_N = R(N-1)$). Az összegzés a "négyzetben" függőleges módszer helyett átlósan történik [ÁBRA] a főátlóval párhuzamos diagonálisok mentén, hiszen ott $t-s = \tau$ állandó. Ezzel $D^2\bar{X} = \frac{1}{N^2} \sum_{\tau=-(N-1)}^{N-1} (N-|\tau|) \cdot$

¹itt $|\Sigma|$ a Σ determinánsát jelöli

$R(\tau) = \frac{1}{N} \cdot \sum_{\tau=-(N-1)}^{N-1} \left(1 - \frac{|\tau|}{N}\right) \cdot R(\tau) = (*)$. Most álljunk meg egy percre, és emlékezzünk a Cesaro-féle összegre: $\sum_{\tau=1}^{\infty} a_{\tau} < \infty$ biztosítja, hogy a $\lim_{T \rightarrow \infty} \sum_{\tau=1}^{T-1} \left(1 - \frac{\tau}{T}\right) a_{\tau} = \sum_{\tau=1}^{\infty} a_{\tau}$ határérték létezik és véges. Alkalmazzuk ezt $D^2\bar{X}$ -ra: $\lim_{N \rightarrow \infty} \sum_{\tau=-(N-1)}^{N-1} \left(1 - \frac{|\tau|}{N}\right) R(\tau) = \sum_{\tau=-\infty}^{\infty} R(\tau)$, tehát ha ez utóbbi összeg létezik és véges, akkor $\lim_{N \rightarrow \infty} N \cdot D^2\bar{X} = \sum_{\tau=-\infty}^{+\infty} R(\tau)$. Mivel $\varphi(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{i\lambda t} R(t) dt = \frac{1}{2\pi} \cdot \sum_{\tau=-\infty}^{+\infty} e^{i\lambda\tau} R(\tau)$, így $2\pi \cdot \varphi(0) = \sum_{-\infty}^{+\infty} R(\tau)$. Ezzel a következő állításhoz jutottunk:

Állítás 6.1.2. $\lim_{N \rightarrow \infty} N \cdot D^2\bar{X} = 2\pi\varphi(0)$, azaz az átlag szórásnégyzetére fennáll

$$D^2\bar{X} \sim \frac{2\pi\varphi(0)}{N}.$$

Példa 6.1.3. Egy $AR(1)$ folyamatra $2\pi\varphi(0) = \sigma^2 \cdot \left(\frac{1+\alpha}{1-\alpha}\right)$ (2.4-ben számoltunk ilyen általánosabban, amiből látszik, hogy $|\alpha| < 1$ szükséges), azaz $D^2\bar{X} \sim \frac{\sigma^2}{N} \cdot \left(\frac{1+\alpha}{1-\alpha}\right)$. Tehát a független megfigyelésekkel megegyező pontosságú becsléshez $\left(\frac{1+\alpha}{1-\alpha}\right)$ -szor annyi megfigyelésre van szükség. ($\alpha = 0$ esetén fehér zaj, $\alpha = 1$ -re pedig felrobban a folyamat)

A spektrálreprezentációhoz visszatérve: mi van akkor, ha nincs spektrálsűrűség-függvény? Spektrálmérték ekkor is van és ezzel írhatjuk, hogy

$$D^2\bar{X} = \frac{1}{N^2} \cdot \sum_{t,s=1}^N R(t-s) =$$

$$= \frac{1}{N^2} \sum_{t,s=1}^N \int_{-\pi}^{\pi} e^{i\lambda t} \cdot \overline{e^{i\lambda s}} dF(\lambda) = \frac{1}{N^2} \cdot \int_{-\pi}^{\pi} \left| \sum_{t=1}^N e^{i\lambda t} \right|^2 dF(\lambda) = (*)$$

Az abszolútérték jelen belül vizsgálódva írjuk fel a szummát

$$\begin{aligned} \sum_{t=1}^N e^{i\lambda t} &= e^{i\lambda} \cdot \frac{1 - e^{i\lambda N}}{1 - e^{i\lambda}} = \\ &= e^{i\lambda} \cdot \frac{e^{i\lambda \frac{N}{2}} \left(e^{-i\lambda \frac{N}{2}} - e^{i\lambda \frac{N}{2}} \right)}{e^{i\lambda \frac{1}{2}} \left(e^{-i\lambda \frac{1}{2}} - e^{i\lambda \frac{1}{2}} \right)} = e^{i\lambda \cdot \frac{N-1}{2}} \cdot \frac{\sin \frac{\lambda N}{2}}{\sin \frac{\lambda}{2}} \end{aligned}$$

alakban. Ezzel a fenti tovább folytatható:

$$(*) = \frac{1}{N^2} \int_{-\pi}^{\pi} \frac{\sin^2 \frac{N\lambda}{2}}{\sin^2 \frac{\lambda}{2}} dF(\lambda) = (**).$$

$\lambda = 0$ -ban N^2 -ként értelmezzük a függvényt². Hová tart ez, ha N -nel tartunk végtelenbe? Mivel $\frac{1}{N^2} \cdot \frac{\sin^2 \frac{N\lambda}{2}}{\sin^2 \frac{\lambda}{2}} \rightarrow 0$, ha $\lambda \neq 0$, de $\lambda = 0$ esetén ez a határérték 1. Az integrandus tehát pontonként tart a $\mathbf{1}_{\{0\}}$ függvényhez. Tehát $D^2 \overline{X} = (**)$ $\rightarrow \int_{-\pi}^{\pi} \mathbf{1}_{\{0\}} dF(\lambda) = F(\{0\})$, azaz a $\{0\}$ spektrálmértékhez. Persze fontos még látnunk, hogy az integrandus korlátos³, amit a $\Theta = \frac{N\lambda}{2}$ jelölés mellett könnyen ellenőrizhetünk, tudniillik

$$\frac{1}{N^2} \frac{\sin^2 \Theta}{\sin^2 \left(\frac{\Theta}{N} \right)} = \frac{\sin^2 \Theta}{\Theta^2} : \frac{\sin^2 \left(\frac{\Theta}{N} \right)}{\left(\frac{\Theta}{N} \right)^2} \sim \frac{\sin^2 \Theta}{\Theta^2} \xrightarrow{\Theta \rightarrow 0} 1.$$

Tehát a 0 körül korlátos, egyébként pedig nyilvánvaló, hiszen $\frac{\lambda}{2}$ csak $\frac{\pi}{2}$ -ig megy. Ezzel

²Hiszen határátmenettel is ezt kapjuk.

³Ez elegendő a Lebesgue-tétel alkalmazhatóságához, ti. korlátos függvény valószínűségi mérték szerint integrálható, így van integrálható majoráns.

Állítás 6.1.4. \bar{X} pontosan akkor lesz a μ (várható érték) konzisztens becslése, ha $F(\{0\}) = 0$, azaz a spektrális eloszlásfüggvény folytonos a 0-ban.⁴

Vajon miért csak a spektrum origó körüli viselkedésétől függ \bar{X} konvergenciája?

Definíció 6.1.5. Az $X(t) = \sum_{i=1}^K A_i \cos(\lambda_i t + \phi_i)$ folyamatot **harmonikus folyamatnak** nevezzük, ahol $\phi_i \sim U(-\frac{\pi}{2}, \frac{\pi}{2})$ minden i -re független valószínűségi változó (ún. véletlen fázis), K , A_i -k, λ_i -k pedig konstansok.

Ezen folyamat autokorreláció-függvénye

$$r(\tau) = \frac{R(\tau)}{R(0)} = \frac{\sum_{i=1}^K (\frac{1}{2}A_i^2) \cdot \cos(\lambda_i \tau)}{\sum_{i=1}^K (\frac{1}{2}A_i^2)}.$$

A harmonikus folyamatok arról nevezetesek, hogy tiszta diszkrét spektrummal rendelkeznek. Ha λ_i -k összemérhetőek, akkor a trajektóriák ráadásul periodikus függvények. Ha a 0 is spektrumpont, akkor valamelyik $\lambda_i = 0$, és így

$$X(t) = A \cdot \cos \phi + Y(t),$$

ahol $Y(t)$ a szumma többi tagja. Az első tag tehát időben konstans! Itt

$$EX(t) = E(A \cos \phi) + EY(t) = EY(t),$$

mivel $E(A \cos \phi) = A \cdot (E \cos \phi)$, és az utóbbi kiintegrálva láthatóan 0. Ugyanakkor minden trajektóriára $\phi(\omega)$ konstans, tehát $A \cos \phi(\omega) \neq 0$.

⁴Abszolút folytonos esetben (tehát, ha létezik spektrálsűrűség-függvény) ez nyilván teljesül.

Mivel ez is konstans az időben, ezért

$$\bar{X}(\omega) = \frac{1}{N} \sum_{t=1}^N X(t, \omega) = A \cos \phi(\omega) + \frac{1}{N} \sum_{t=1}^N Y(t, \omega),$$

és így

$$D^2 \bar{X} = D^2(A \cos \phi) + D^2 \bar{Y} \rightarrow 0.$$

7. fejezet

A kovarianciafüggvény becslése

7.1. A tapasztalati autokovariancia

A kovarianciafüggvényre a következő becslést adhatjuk:

$$\hat{R}^*(\tau) = \frac{1}{N - |\tau|} \sum_{t=1}^{N-|\tau|} (X_t - \bar{X})(X_{t+|\tau|} - \bar{X}).$$

Természetesen ha a μ várható érték ismert, akkor az átlagot lecserélhetjük erre, azaz a becslés

$$\hat{R}_\mu^*(\tau) = \frac{1}{N - |\tau|} \sum_{t=1}^{N-|\tau|} (X_t - \mu)(X_{t+|\tau|} - \mu).$$

Megjegyzés 7.1.1.

1. Nyilván $|\tau| \geq N - 1$ -re nem tudunk becslést adni.
2. Térátlagok helyett most is időátlagokat nézünk.
3. \hat{R}^* nyilván páros függvény.

Ha μ ismert, akkor \hat{R}_μ^* torzítatlan becslés, azaz

$$\begin{aligned} E\hat{R}_\mu^*(\tau) &= \frac{1}{N - |\tau|} \sum_{t=1}^{N-|\tau|} E [(X_t - \mu)(X_{t+|\tau|} - \mu)] = \\ &= \frac{1}{N - |\tau|} \sum_{t=1}^{N-|\tau|} R(\tau) = R(\tau). \end{aligned}$$

Ha pedig μ nem ismert, akkor a becslés torzít, ellenben aszimptotikusan torzítatlan. Számítsuk ki a torzítást:

$$\begin{aligned} \hat{R}_\mu^*(\tau) &= \frac{1}{N - |\tau|} \sum_{t=1}^{N-|\tau|} ((X_t - \bar{X}) + (\bar{X} - \mu)) ((X_{t+|\tau|} - \bar{X}) + (\bar{X} - \mu)) \approx \\ &\approx \frac{1}{N - |\tau|} \left\{ \sum_{t=1}^{N-|\tau|} [(X_t - \bar{X})(X_{t+|\tau|} - \bar{X})] + (N - |\tau|)(\bar{X} - \mu)^2 \right\}, \end{aligned}$$

ahol ez utóbbi (\approx) lépésben elhanyagoltuk az úgynevezett véghatást, vagyis "kihasználtuk", hogy $\sum_{t=1}^{N-|\tau|} (X_t - \bar{X}) \sim \sum_{t=1}^N (X_t - \bar{X}) = 0$.¹ Ezt átrendezve kapjuk, hogy $\hat{R}_\mu^*(\tau) - (\bar{X} - \mu)^2 \approx \hat{R}^*(\tau)$. Vegyünk várható értéket mindkét oldalon és használjuk ki \hat{R}_μ^* torzítatlanságát, ezzel $R(\tau) - D^2\bar{X} \approx E\hat{R}^*(\tau)$. Ha az $N \rightarrow \infty$ határértéket nézzük, akkor már egyenlőség is írható (ehhez csak azt kell megmutatni, hogy a véghatás várható értéke tart 0-hoz). Így a $D^2\bar{X}$ -ra kapott konvergenciasebesség szerint – ha például létezik spektrálsűrűségfüggvény –

$$\lim_{N \rightarrow \infty} E\hat{R}^*(\tau) = R(\tau)$$

és

$$\lim_{N \rightarrow \infty} N \cdot E(\hat{R}^*(\tau) - R(\tau)) = -2\pi \cdot \varphi(0),$$

¹Ez akkor lesz igaz, ha $N \gg |\tau|$.

vagyis a torzítás $\frac{2\pi\varphi(0)}{N}$ nagyságrendű. Később látni fogjuk, hogy ez a torzítás kisebb, mint a becslés fluktuációja, tehát első közelítésben elhanyagolható. Létezik másik, kedvezőbb tulajdonságú becslés, amely ismeretlen μ esetén

$$\hat{R}(\tau) = \frac{1}{N} \sum_{t=1}^{N-|\tau|} (X_t - \bar{X})(X_{t+|\tau|} - \bar{X})$$

alakú, ismertre pedig

$$\hat{R}_\mu(\tau) = \frac{1}{N} \sum_{t=1}^{N-|\tau|} (X_t - \mu)(X_{t+|\tau|} - \mu).$$

Két dolog indokolja $\hat{R}(\tau)$ bevezetését. Egyrészt egy kovarianciafüggvénytől elvárjuk, hogy pozitív szemidefinit legyen, és $\hat{R}(\tau)$ -ról ez be is látható, szemben $\hat{R}^*(\tau)$ -val, amelyre ez a tulajdonság nem feltétlenül teljesül. Másrészt látni fogjuk, hogy míg $\hat{R}(\tau)$ szórásnégyzete $\frac{1}{N}$ nagyságrendű minden τ -ra, addig $\hat{R}^*(\tau)$ -é $\frac{1}{N-|\tau|}$, vagyis az autokovariancia függvény végét mindig csak bizonytalanul becsülhetjük \hat{R}^* -gal². Márpedig az autokovariancia függvényt általában nem τ -nként akarjuk becsülni, hanem az összes τ -ra 0-tól $N-1$ -ig egyszerre, azaz: mi magára az $R(\tau)$ függvényre vagyunk kíváncsiak (nem az egyes értékeire).

Most lássuk $\hat{R}_\mu(\tau)$ torzítását: mivel

$$E(\hat{R}_\mu(\tau)) = \frac{1}{N} \sum_{t=1}^{N-|\tau|} R(\tau) = \left(1 - \frac{|\tau|}{N}\right) \cdot R(\tau),$$

így

$$E(\hat{R}_\mu(\tau) - R(\tau)) = -\frac{|\tau|}{N} \cdot R(\tau)$$

²Nagyobb τ esetén nagyobb lesz a szórás.

a torzítás. Ennek nagyságrendje $|\tau|$ és N relatív nagyságától, és $R(\tau)$ -tól függ. Ha $|\tau|$ relatíve kicsi N -hez képest, akkor a torzítás ezért kicsi, míg ha $|\tau|$ és N közeli, akkor $R(\tau)$ nagyságrendű, ami folytonos spektrum esetén 0-hoz tart ($\tau \rightarrow \infty$), így ezért kicsi.

$\hat{R}(\tau)$ torzítására spektrálsűrűségfüggvény léte mellett

$$E(\hat{R}(\tau) - R(\tau)) \sim -\frac{|\tau|}{N}R(\tau) - \frac{2\pi(N - |\tau|)}{N^2}\varphi(0)$$

adódik³.

7.2. A becslés varianciája és kovarianciája

Csak \hat{R}_μ , tehát ismert várható érték mellett van esélyünk számolni, és még ez sem túl szép. Az általánosság megszorítása nélkül tegyük fel, hogy $\mu = 0$, azaz \hat{R}_0 kovarianciáját keressük. Tegyük fel továbbá, hogy X_t negyedrendig stacionárius⁴.

$$\text{cov}(\hat{R}_0(\tau), \hat{R}_0(\tau + \vartheta)) = E\left(\hat{R}_0(\tau) \cdot \hat{R}_0(\tau + \vartheta)\right) - E\hat{R}_0(\tau)E\hat{R}_0(\tau + \vartheta) = (*)$$

Mivel $E\hat{R}_0(\tau) = \left(1 - \frac{|\tau|}{N}\right)R(\tau)$ és $\hat{R}_0(\tau) = \frac{1}{N} \sum_{t=1}^{N-|\tau|} X_t X_{t+|\tau|}$, így, ha $\tau, \vartheta \geq 0$, akkor

$$\begin{aligned} (*) &= \frac{1}{N^2} \cdot E\left(\sum_{t=1}^{N-\tau} \sum_{s=1}^{N-\tau-\vartheta} X_t \cdot X_{t+\tau} \cdot X_s \cdot X_{s+\tau+\vartheta}\right) - \\ &\quad - \left(1 - \frac{\tau}{N}\right) \cdot \left(1 - \frac{\tau + \vartheta}{N}\right) \cdot R(\tau) \cdot R(\tau + \vartheta) \end{aligned}$$

³ \hat{R}^* -nál levő számoláshoz teljesen hasonló.

⁴ez azt jelenti, hogy egy $E[X_t X_{t+u} X_{t+v} X_{t+w}]$ alakú kifejezés csak u, v, w -tól függ (t -tól nem).

A négyes szorzat várható értéke csak $t - s, \tau, \vartheta$ -tól függ a negyedrendű stacionaritás miatt. Egy négyes szorzat várható értéke pedig kifejezhető a kumulánsával.

Definíció 7.2.1. X_1, \dots, X_k valószínűségi változók együttes karakterisztikus függvénye legyen

$\varphi(t_1, \dots, t_k)$. A $\log \varphi$ létezik a 0 egy környezetében és sorbafejthető:

$$\log \varphi(t_1, \dots, t_k) = \sum_{\nu_1 + \dots + \nu_k \leq n} \frac{i^{\nu_1 + \dots + \nu_k}}{\nu_1! \cdot \dots \cdot \nu_k!} s^{(\nu_1, \dots, \nu_k)} t_1^{\nu_1} \cdot \dots \cdot t_k^{\nu_k} + o(|t|^n).$$

Ezen $s^{(\nu_1, \dots, \nu_k)}$ -kat (vegyes) **szemiinvariánsok**nak, más néven kumulánsoknak nevezzük.

A fenti szorzat várható értéke $s^{(1,1,1,1)}$ -ben fordul elő. A k -adrendű (vegyes) szemiinvariánsok kifejezhetők a legfeljebb k -adrendű kevert momentumokkal⁵. Mivel a kevert momentumok rendje legfeljebb 4 - egyezően s rendjével -, ha abban elsőrendű tag is fellép, akkor az a tag $EX_t = 0$ miatt 0 lesz. Így az általános formulában csak a negyed- és másodfokú tagok adnak nullától különbözőt. Tehát

$$\kappa = s^{(1,1,1,1)} =$$

$$\begin{aligned} & E(X_t X_{t+\tau} X_s X_{s+\tau+\vartheta}) - E(X_t X_{t+\tau}) \cdot E(X_s X_{s+\tau+\vartheta}) - \\ & - E(X_t X_s) \cdot E(X_{t+\tau} X_{s+\tau+\vartheta}) - E(X_t X_{s+\tau+\vartheta}) \cdot E(X_{t+\tau} X_s) \end{aligned}$$

Használjuk ki a negyedrendű stacionaritást, így a várható értékek csak $m = s - t$ -től függenek.

⁵Többek között ez az állítás is megtalálható A. N. Shiryaev - Probability című könyvének második kiadásában (a 290. oldal).

Még előbb: az első kivonandó κ -ban $= R(\tau) \cdot R(\tau + \vartheta)$ független t -től és s -től, így (*)-ban kiejti a szummázás utáni (levont) tagot. Továbbá κ -ban a másik két kivonandó $R(s-t) \cdot R(s-t+\vartheta)$, illetve $R(s-t+\tau+\vartheta) \cdot R(s-t-\tau)$, így

$$(*) = \frac{1}{N^2} \sum_{t=1}^{N-\tau} \sum_{s=1}^{N-\tau-\vartheta} \{R(s-t) \cdot R(s-t+\vartheta) + \\ + R(s-t+\tau+\vartheta) \cdot R(s-t-\tau) + \kappa(s-t, \tau, \vartheta)\} = (**)$$

Használjuk ki, hogy minden csak $s-t$ -től függ, és összegezzünk $s-t = m$ szerint (a diagonális mentén):

$$(**) = \frac{1}{N} \sum_{m=-(N-\tau)+1}^{N-\tau-\vartheta-1} \left\{ 1 - \frac{\eta(m) + \tau + \vartheta}{N} \right\} \times$$

$$\times \{R(m) \cdot R(m + \vartheta) + R(m + \tau + \vartheta) \cdot R(m - \tau) + \kappa(m, \tau, \vartheta)\},$$

$$\text{ahol } \eta(m) = \begin{cases} m, & m > 0 \\ 0, & -\vartheta \leq m \leq 0 \\ -m - \vartheta, & -(N - \tau) + 1 \leq m < -\vartheta \end{cases} .$$

Ha $X(t)$ Gauss-folyamat, akkor $\kappa = 0$. Ugyanis $\log \varphi(t_i) = -\frac{t_i^2 \sigma^2}{2}$, hiszen a folyamat várható értéke 0, így az együttes karakterisztikus függvény Taylor-sorában nem lesznek t_i -ket elsőfokon tartalmazó tagok, más szóval az $s^{(1,1,1)}$ szemiiinvariáns értéke 0. Ez pedig pont azt eredményezi, hogy $\kappa = 0$ minden m, τ, ϑ -ra.

$\vartheta = 0$ -ra $D^2 \hat{R}_0(\tau)$ -t kapjuk:

$$D^2 \hat{R}_0(\tau) = \frac{1}{N} \sum_{m=-(N-\tau)+1}^{N-\tau-1} \left(1 - \frac{|m| + \tau}{N} \right) \cdot (R^2(m) + R(m + \tau) \cdot R(m - \tau)) .$$

Ez újra egy Cesaro-típusú összeg, aminek a határértéke $\sum_{m=-\infty}^{\infty} (R^2(m) + R(m + \tau) \cdot R(m - \tau))$ feltéve, hogy ez véges. Továbbá $\vartheta \neq 0$ és nagy N esetén

$$\text{cov} \left(\hat{R}_0(\tau), \hat{R}_0(\tau + \vartheta) \right) \sim \frac{1}{N} \sum_{m=-\infty}^{\infty} \{ R(m) \cdot R(m + \vartheta) + R(m + \tau + \vartheta) \cdot R(m - \tau) \},$$

és ugyanígy $\vartheta = 0$ -ra

$$D^2 \hat{R}_0(\tau) \sim \frac{1}{N} \sum_{m=-\infty}^{+\infty} (R^2(m) + R(m + \tau) \cdot R(m - \tau)),$$

ami Bartlett eredménye 1946-ból. Innen speciálisan $X(t)$ szórásnégyzetének becslésére $\hat{\sigma}^2 = \hat{R}_0(0)$ és ennek szórásnégyzetére

$$D^2(\hat{\sigma}^2) \sim \frac{2}{N} \sum_{m=-\infty}^{+\infty} R^2(m) = \frac{2\sigma^4}{N} \sum_{m=-\infty}^{+\infty} \varrho^2(m)$$

adódik, ahol ϱ az autokorreláció-függvény. Fehér zajra pedig visszkapjuk a tapasztalati szórásnégyzetre vonatkozó $D^2 S_n^2 \sim \frac{2\sigma^4}{N}$ nagyságrendet (független mintavétel stb.).

Vegyük észre, hogy az aszimptotikus kifejezésben diszkrét konvolúciók állnak⁶. Az első tag $R(\tau)$ konvolúciója önmagával a ϑ helyen, a második ugyanez a $2\tau + \vartheta$ helyen (például bevezethetjük az $l = m - \tau - t$ futóindexet, és eszerint összegezzük). Tegyük fel, hogy létezik spektrál-sűrűségfüggvény. Ekkor az R önmagával vett konvolúciója nem más, mint $\varphi^2(\lambda)$ -nak, azaz a spektrál-sűrűségfüggvénynek a Fourier-transzformáltja⁷.

⁶Konvolúciót úgy lehet könnyen felismerni, ha észrevesszük, hogy az argumentumok különbsége állandó.

⁷ $f * g = \mathfrak{F}(f) \cdot \mathfrak{F}(g)$

Ezzel

$$\text{cov} \left(\hat{R}_0(\tau), \hat{R}_0(\tau + \vartheta) \right) \sim \frac{2\pi}{N} \int_{-\pi}^{\pi} \left(e^{i\lambda\vartheta} + e^{i\lambda(2\tau+\vartheta)} \right) \cdot \varphi^2(\lambda) d\lambda$$

és

$$D^2 \left(\hat{R}_0(\tau) \right) \sim \frac{2\pi}{N} \int_{-\pi}^{\pi} (1 + e^{2i\lambda\tau}) \varphi^2(\lambda) d\lambda$$

Speciálisan standard normális fehér zajra $\varphi^2(\lambda) = \left(\frac{1}{2\pi}\right)^2$, ezzel

$$N \cdot \text{cov} \left(\hat{R}_0(\tau), \hat{R}_0(\tau + \vartheta) \right) \longrightarrow \begin{cases} 0, & \text{ha } \vartheta \neq 0 \\ \frac{1}{2\pi}, & \text{ha } \vartheta = 0 \end{cases}$$

Megjegyzés 7.2.2. Mivel τ és ϑ egészek, ezért például $\int_{-\pi}^{\pi} e^{i\lambda\tau} d\lambda = 0$.⁸

$AR(1)$ esetén $\varrho(m) = \alpha^{|m|}$ ⁹, így a fentebbiek alapján $D^2 \left(\hat{R}_0(0) \right) = D^2(\hat{\sigma}) \sim \frac{2\sigma^4}{N} \cdot \left(\frac{1+\alpha^2}{1-\alpha^2} \right)$. Tehát ez esetben $\frac{1+\alpha^2}{1-\alpha^2}$ -szer annyi megfigyelésre van szükség azonos "bizonyosság" eléréséhez σ^2 becslésében, mint független megfigyelések esetén.

Mi lesz a torzítatlan becsléssel \hat{R}_0^* esetén? (Legyen $\tau > 0$.) Mivel $\hat{R}_0^* = \frac{N}{N-\tau} \hat{R}_0$, így csupán a szummán kívül a nevezőt kell változtatnunk $\frac{1}{N}$ -ről $\frac{1}{N-\tau}$ -ra. Ez bizonyítja, amit az elején állítottunk, hogy míg $D^2 \hat{R}_0(\tau) = O\left(\frac{1}{N}\right)$, addig $D^2 \hat{R}_0^*(\tau) = O\left(\frac{1}{N-\tau}\right)$.

Most foglalkozzunk az autokorreláció-függvény becslésével. Mivel $\varrho(\tau) = \frac{R(\tau)}{R(0)}$, ezért egészen természetes gondolat ϱ becslésének $\hat{\varrho} = \frac{\hat{R}(\tau)}{\hat{R}(0)}$ -t elfogadnunk (illetve ugyanez indexszel és/vagy *-gal ellátva). $\hat{\varrho}_0^*(\tau)$ további ked-

⁸ e^{it} ugye 2π -nként periodikus

⁹2.2 után számoltuk ki, $0 < \alpha < 1$

vezőtlen tulajdonsága lesz, hogy míg $|\varrho(\tau)| \leq 1$, addig ez $\hat{\varrho}_0^*$ -ra nem teljesül, ám $\hat{\varrho}_0$ teljesíti (a pozitív szemidefinitésnél is ugyanaz a probléma lép fel, mint amit az autokovariancia-függvény becslésénél is láttunk). Mivel $\hat{\varrho}$ kvadratikus alakok hányadosa, így érthető, hogy a becslések pontos eloszlása, illetve tulajdonságai nagyon bonyolultak. Approximációs technikával határeloszlásra egy ismert eredmény Lomnickitől és Zarembától származik 1957-ből, amit most nem részletezünk. 1946-ban Bartlett a következőt bizonyította:

$$D^2(\hat{\varrho}_0(\tau)) \sim \frac{1}{N} \sum_{m=-\infty}^{+\infty} [\varrho^2(m) + \varrho(m+\tau) \cdot \varrho(m-\tau) + 2\varrho^2(\tau) \cdot \varrho^2(m) - 4 \cdot \varrho(\tau) \cdot \varrho(m) \cdot \varrho(m-\tau)].$$

A korábban $\hat{R}_0(\tau)$ -nál látott, kumulánst is felhasználó bizonyításhoz teljesen hasonló technikával dolgozik, azonban érdemes megjegyezni, hogy itt $\kappa(m, \tau, \vartheta)$ nemcsak akkor lesz 0, ha Gauss-folyamatról van szó, hanem már az is elegendő, hogy az $X(t)$ folyamat lineáris legyen, emellett pedig az $\varepsilon(t)$ zaj független értékű legyen, ne csak korrelálatlan. Általában elég nagy korreláció lesz az autokorreláció-függvény szomszédos pontjaiban becsült értékek között (hasonló a helyzet az autokovariancia-függvény esetén). Ezért a becsült autokorreláció-függvény nem cseng le olyan gyorsan, mint az eredeti.

Fehér zajra $\text{cov}(\hat{\varrho}_0(\tau), \hat{\varrho}_0(\tau + \vartheta)) \sim 0$, ha ϑ pozitív, és $D^2\hat{\varrho}_0(\tau) \sim \frac{1}{N}$, ha τ pozitív. Gyorsan lecsengő autokorreláció-függvényre, ha $\varrho(s) \xrightarrow{|s| \rightarrow \infty} 0$, akkor $|s| \geq \tau$ -ra $\varrho(s) \sim 0$. Ekkor pedig a becslés redukálódik:

$$\text{cov}(\hat{\varrho}_0(\tau), \hat{\varrho}_0(\tau + \vartheta)) \sim \frac{1}{N} \sum_{m=-\infty}^{+\infty} \varrho(m) \cdot \varrho(m + \vartheta)$$

$$D^2(\hat{\rho}_0(\tau)) \sim \frac{1}{N} \cdot \sum_{m=-\infty}^{+\infty} \varrho^2(m)$$

Vegyük észre, hogy a becslés kovarianciája csak ϑ -tól függ, ha τ elég "nagy", azaz a becslés egy stacionárius folyamatként viselkedik, amely azonban erősebben autokorrelált, mint az eredeti $X(t)$ folyamat.

7.3. A becslések határeloszlásai

Vajon miért van ilyenre szükségünk? Mivel a centrális határeloszlás-tételnek a legkülönbözőbb általánosításai ismertek, így nem túl meglepő módon megfelelő körülmények között az \bar{X} határeloszlása is normális lesz. Ennek kapcsán a következőt állítjuk.

Tétel 7.3.1 (T. W. Anderson, 1971.). *Legyen $X(t)$ lineáris folyamat, azaz*

$$X(t) = \mu + \sum_{s=-\infty}^{+\infty} g(s) \cdot \varepsilon_{t-s},$$

ahol ε_t -k független, azonos eloszlásúak 0 várható értékkel és véges szórásnégyzettel, továbbá legyen $\sum_{s=-\infty}^{+\infty} |g_s| < \infty$. Ekkor

$$\sqrt{N} \cdot (\bar{X} - \mu) \xrightarrow{d} N \left(0, \sum_{\tau=-\infty}^{+\infty} R(\tau) \right),$$

ha $N \rightarrow \infty$, így ha létezik $\varphi(\lambda)$ spektrál-sűrűségfüggvény, és az korlátos 0-ban, akkor

$$\sqrt{N} \cdot (\bar{X} - \mu) \xrightarrow{d} N(0, 2\pi\varphi(0)) \quad (N \rightarrow \infty).$$

Az $\hat{R}_0(\tau)$, illetve $\hat{\rho}_0(\tau)$ egzakt eloszlása véges N -re nincs meghatározva. Aszimptotikus eredményünk azonban van 1971-ből, ami szintén Anderson nevéhez fűződik. Az alapötlet szerint vezessük be az $Y_t = X_t \cdot X_{t+\tau}$ újabb stacionárius folyamatot, és ekkor $\hat{R}_0(\tau)$ egyszerűen e folyamat átlaga, azaz $\hat{R}_0(\tau) = \frac{Y_1 + \dots + Y_{N-\tau}}{N}$.

Tétel 7.3.2. *Legyen $X(t)$ a fent látott lineáris folyamat, de tegyük még fel, hogy $E\varepsilon^4(t)$ véges. Ekkor*

$$\left[\sqrt{N} \cdot \left[\hat{R}(0) - R(0) \right], \dots, \sqrt{N} \cdot \left[\hat{R}(n) - R(n) \right] \right]$$

tart egy 0 várható értékű Gauss-vektorhoz, amelynek kovarianciája $X(t)$ Gauss-folyamat esetén (és a τ , illetve ϑ -adik tag esetén) $\sum_{m=-\infty}^{+\infty} R(m)R(m+\vartheta) + R(m+\tau+\vartheta)R(m-\tau)$.

7.3.1. Stabilis eloszlások

Definíció 7.3.3. X eloszlása **korlátlanul osztható**, ha minden n -re léteznek olyan $X_{n,1}, \dots, X_{n,n}$ valószínűségi változók, amelyek teljesen függetlenek és azonos eloszlásúak, és

$$X = X_{n,1} + \dots + X_{n,n} - A_n,$$

ahol A_n konstans. Ez ekvivalens azzal, hogy X eloszlása határeloszlása a $Z_n = X_{n,1} + \dots + X_{n,k_n} - A_n$ független, azonos eloszlású szériák összegének.

Definíció 7.3.4. Az X valószínűségi változó eloszlása **stabilis**, ha minden b_1, b_2 valós számhoz léteznek b, a valós számok úgy, hogy az X eloszlásával megegyező eloszlású és egymástól független X_1, X_2 valószínűségi változókra

$$b_1 X_1 + b_2 X_2 \stackrel{d}{=} bX + a,$$

azaz az eloszlások egyenlősége fennáll.

Ezzel a definícióval ekvivalens a következő:

Definíció 7.3.5. Az X valószínűségi változó eloszlása pontosan akkor **stabilis**, ha létezik olyan X_1, X_2, \dots független, azonos eloszlású valószínűségi változókból álló sorozat, valamint hozzá $a_n > 0$ és b_n valós számsorozatok, hogy

$$\frac{S_n - a_n}{b_n} \xrightarrow[n \rightarrow \infty]{d} X,$$

ahol $S_n = \sum_{i=1}^n X_i$.¹⁰

Néhány állítást mondunk ki bizonyítás nélkül.

Állítás 7.3.6. Minden stabilis eloszlás korlátlanul osztható.

Állítás 7.3.7. Korlátlanul osztható eloszlások gyenge - azaz eloszlásbeli - határértéke is korlátlanul osztható.

Állítás 7.3.8. A normális eloszlás stabilis (a centrális határeloszlás-tétel miatt), így korlátlanul osztható.

Állítás 7.3.9. A normális az egyetlen véges szórású stabilis eloszlás.

Állítás 7.3.10. A Cauchy-eloszlás stabilis. ($\varphi(t) = e^{-|t|}$, $\frac{X_1+X_2}{2} \sim X_1$)

Állítás 7.3.11. A Poisson-eloszlás korlátlanul osztható, de nem stabilis (van sok véges szórású, korlátlanul osztható eloszlás).

Állítás 7.3.12. A G eloszlásfüggvény pontosan akkor egy stabilis eloszlás eloszlásfüggvénye, ha minden $b_1, b_2 \in \mathbb{R}$ -re létezik $a, b \in \mathbb{R}$, hogy $G\left(\frac{x}{b_1}\right) * G\left(\frac{x}{b_2}\right) = G\left(\frac{x-a}{b}\right)$, ahol $*$ a konvolúciót jelöli.

¹⁰Ez a centrális határeloszlás-tétel egy általánosítása.

Megemlítünk egy, a stabilis eloszlások karakterisztikus függvényére vonatkozó állítást.

Állítás 7.3.13. *X pontosan akkor stabilis eloszlású, ha karakterisztikus függvénye előállítható, mint*

$$\log \varphi_X(t) = \lambda [it\gamma - |t|^\alpha + it\Psi(t, \alpha, \beta)],$$

ahol $0 < \alpha \leq 2$, $-1 \leq \beta \leq 1$, $-\infty < \gamma < \infty$, $\lambda > 0$ és $\Psi(t, \alpha, \beta) =$

$$\begin{cases} |t|^{\alpha-1} \cdot \beta \cdot \operatorname{tg}(\alpha \cdot \frac{\pi}{2}), & \text{ha } \alpha \neq 1 \\ -\beta \cdot \frac{2}{\pi} \cdot \log |t|, & \text{ha } \alpha = 1 \end{cases}.$$

Megjegyzés 7.3.14. $\alpha = 2, \beta = 0, \lambda = \frac{1}{2}$ -re az eloszlás Gauss, $\alpha = 1, \beta = 0, \gamma = 0, \lambda = 1$ -re pedig Cauchy.

Állítás 7.3.15. *A korlátlanul osztható eloszlások karakterisztikus függvénye a következő alakban írható fel:*

$$\log \varphi_X(t) = ita - bt^2 + \int_{\{x \neq 0\}} (e^{itx} - 1 - it \cdot \sin x) dH(x),$$

ahol a, b nemnegatív számok, $H(x)$ Lévy-mérték (mag), amely monoton a félegyeneseken, $|x| \rightarrow \infty$ esetén tart 0-hoz, továbbá $\int_{0 < |x| < 1} x^2 dH(x)$ véges.

11

Stabilis eloszlások a Gauss, Cauchy és a Lévy $f(x) = \frac{1}{2\sqrt{\pi}} x^{-\frac{3}{2}} e^{-\frac{1}{4x}}$ ($x > 0$).

7.3.2. Határeloszlás, amikor a CHT nem érvényes

Mit mondhatunk az autokovariancia-függvény (ACVF) becsléséről, ha nemlineáris folyamatokat vizsgálunk? Ha például az eloszlás reguláris változású

¹¹Bármely korlátlanul osztható eloszlás az Gaussok és Poissonok konvolúciójának határértéke.

$\kappa_1 < 2$ indexszel, akkor nem létezik második momentum, így az $R(k)$ autokovariancia függvény sem, de $\hat{R}(k)$ természetesen felírható. Nézzük meg $GARCH(p, q)$ folyamatra, hogy milyen tulajdonságú. Tegyük fel, hogy a stacionárius oksági megoldás létezik, és annak reguláris változású eloszlására vonatkozó tétel feltételei teljesülnek. Ekkor a következő tétel igaz.

Tétel 7.3.16.

1) A fenti feltételek mellett, ha a regularitási index $\kappa_1 \in (0, 2)$, akkor nincs véges szórás, és így nem létezik $R(k)$ autokovariancia függvény sem. A becslés azonban számolható, és ekkor

$$\left[n^{1-\frac{2}{\kappa_1}} \cdot \hat{R}(k) \right]_{k=1, \dots, m} \xrightarrow{d} [V_k]_{k=1, \dots, m},$$

ahol V_k $\frac{\kappa_1}{2}$ -stabilis \mathbb{R}^m -beli vektorváltozó.

Megjegyzés 7.3.17. Ebben az esetben n kitevője negatív, vagyis $\hat{R}(k)$ eleve $n^{\frac{2}{\kappa_1}-1}$ nagyságrendben nő. Még ha ezzel leosztjuk, akkor is erősen fluktuáló eloszláshoz tart (mivel végtelen a szórásnégyzet).

2) A fenti feltételek mellett, ha a regularitási index $\kappa_1 \in (2, 4)$ akkor $EX^2(t)$ véges, de $EX^4(t)$ már végtelen, és így $R(k)$ ugyan létezik, de becslésének szórása még nem. Ekkor

$$\left[n^{1-\frac{2}{\kappa_1}} \cdot \left(\hat{R}(k) - R(k) \right) \right]_k \xrightarrow{d} [V]_k,$$

ahol V_k ugyancsak $\frac{\kappa_1}{2}$ -stabilis vektorváltozó.

Megjegyzés 7.3.18. Most már végtelenhez tartóval szorzunk, tehát a becslés önmagában is lecsökkenne, azaz van konvergencia, de a sebessége $\frac{1}{\sqrt{n}}$ -nél lassabb, mert $0 > \frac{2}{\kappa_1} - 1 > -\frac{1}{2}$.

3) Ha $\kappa_1 \in (4, +\infty)$, akkor

$$\left[\sqrt{n} \left(\hat{R}(k) - R(k) \right) \right]_k \xrightarrow{d} [Gauss]_k,$$

vagyis a klasszikus esetet kapjuk vissza.

Megjegyzés 7.3.19. A fentivel összevetve, a stabilis eloszlás paramétere 2-nél nagyobb lenne, de ez csak a Gauss lehet. A tételnek ezen része az erősen keverő sorozatokra érvényes centrális határeloszlás-tétel alkalmazása.