

## Az idősorelmélet alapfogalmai

**Definíció. Sztochasztikus folyamat:**  $(X_t)_{t \in T}$ , ahol  $T$  a paraméterter és minden  $t$ -re  $X_t$  valószínűségi változó.

Ebben a tárgyban általában  $T = \mathbb{Z}$  vagy  $T = \mathbb{Z}_+$ , sztochasztikus folyamatokban  $T = \mathbb{R}$  vagy  $T = \mathbb{R}_+$ .

**Definíció. Gauss-folyamat:** olyan sztochasztikus folyamat, melynek bármely véges számú peremeloszlása együttesen normális eloszlású, azaz minden  $n \in \mathbb{Z}_+$ ,  $t_1 \in T, \dots, t_n \in T$  esetén  $(X_{t_1}, \dots, X_{t_n})$  együttesen normális eloszlású.

**Idősor:** Olyan sztochasztikus folyamat, amikor a  $T$  paramétertartományra 'idő'-ként gondolunk.

**Definíció. Erős stacionaritás.**  $(X_t)_{t \in T}$  erősen stacionárius, ha minden  $n \in \mathbb{Z}_+$ ,  $t_1 \in T, \dots, t_n \in T$  és  $h \in T$  esetén  $(X_{t_1}, \dots, X_{t_n})$  együttesen ugyanolyan eloszlású, mint a  $h$ -val való eltoltja,  $(X_{t_1+h}, \dots, X_{t_n+h})$ .

**Definíció. Autokovariancia függvény:**  $R(t, s) = \text{cov}(X_t, X_s)$

**Definíció. Gyenge stacionaritás.**  $(X_t)_{t \in T}$  gyengén stacionárius, ha  $EX_t$  nem függ  $t$ -től (azaz konstans), illetve az autokovariancia függvény  $R(t, s)$  értéke csak a  $t - s$  eltéréstől függ.

Gyengén stacionárius idősor autokovariancia függvénye tehát tulajdonképpen egyváltozós, ezt az egyváltozós függvényt is  $R$ -rel fogjuk jelölni:  $R(t, s) = R(t - s)$ . Tehát gyengén stacionárius idősor autokovariancia függvénye  $R(h) = \text{cov}(X_{t+h}, X_t)$  módon számolható.

**Megjegyzés.** A gyenge stacionaritásból nem következik az erős, de az erős stacionaritásból se a gyenge (nem biztos, hogy léteznek momentumai).

**Megjegyzés.** A *stacionaritás* szó bizonyos szempontból időbeli állandóságot, stabilitást jelent.

**Megjegyzés.** A stacionaritás közkedvelt, gyakori feltételezés egy tapasztalati idősorra vonatkozóan, azonban ellenőrzése nem egyszerű. Ha egy idősorban szemmel láthatóan trend vagy szezonális figyelhető meg, akkor nem stacionárius. Az idősorelemzés első lépése mindig a nemstacionárius összetevők (komponensek) kiszűrése.

A továbbiakban feltesszük, hogy az idősor gyengén stacionárius és paramétertere diszkrét.

**Állítás.**  $R(0) = D^2 X_t$  minden  $t$ -re.

**Definíció. Autokorreláció függvény (ACF):**  $r(h) = \text{cor}(X_t, X_{t+h})$ ,  $h \in \mathbb{Z}$ .

**Állítás.**  $r(h) = \frac{R(h)}{R(0)}$

**Definíció. Parciális autokorreláció függvény (PACF):**

$\rho(h) = \text{cor}(X_t, X_{t+h} | X_{t+1}, X_{t+2}, \dots, X_{t+h-1})$ ,  $h \in \mathbb{Z}$ .

**Jelölés.**

- $r_h := r(h)$
- $R_h := \begin{bmatrix} 1 & r_1 & r_2 & \dots & r_{h-1} \\ r_1 & 1 & r_1 & \dots & r_{h-2} \\ r_2 & r_1 & 1 & \dots & r_{h-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{h-1} & r_{h-2} & r_{h-3} & \dots & 1 \end{bmatrix}$
- $R_h^\#$ : a fenti  $R_h$  mátrix utolsó sorát kicseréljük  $r_1, \dots, r_h$  sorra.

**Állítás.**  $\rho(h) = \begin{cases} r_1 & \text{ha } |h| = 1 \\ \frac{\det R_h^\#}{\det R_h} & \text{ha } |h| > 1 \end{cases}$

**Definíció. Független értékű zaj folyamat (independent value noise):**

$\varepsilon_t \sim IVN(0, \sigma^2)$ , ha  $E\varepsilon_t = 0$ ,  $D^2\varepsilon_t = \sigma^2$ , valamint  $\varepsilon_t$  és  $\varepsilon_s$  minden  $t \neq s$  esetén független egymástól.

**Definíció. Fehér zaj folyamat (white noise):**

$\varepsilon_t \sim WN(0, \sigma^2)$ , ha  $E\varepsilon_t = 0$ ,  $D^2\varepsilon_t = \sigma^2$  és  $\text{cov}(\varepsilon_t, \varepsilon_s) = 0$ , ha  $t \neq s$ .

**Megjegyzés.** Gyakran kényelmes feltenni a fehér zajról, hogy Gauss-folyamat, ilyenkor Gauss-féle fehér zajról beszélünk (GWN).

**Definíció. Lineáris folyamat:**

$X_t = \mu + \sum_{j=-\infty}^{\infty} \beta_j \varepsilon_{t-j}$ , ahol  $\mu \in \mathbb{R}$ ,  $\varepsilon_t \sim IVN(0, \sigma^2)$  és  $\sum_{j=-\infty}^{\infty} |\beta_j| < \infty$ .

**Megjegyzés.** A lineáris folyamat definíciójában lévő  $\varepsilon_t$  zaj folyamatot *innovációnak* vagy *meghajtó folyamatnak* is szokták nevezni. Ez az elnevezés más modellek esetén is használatos.

**Állítás.** Az  $X_t$  lineáris folyamat stacionárius.

**Definíció. MA( $\infty$ ) folyamat:** Olyan lineáris folyamat, amely nem függ a zaj jövőbeli értékeitől, azaz  $\beta_{-1} = \beta_{-2} = \dots = 0$ .

**Megjegyzés.** MA=moving average, magyarul mozgóátlag.

**Megjegyzés.** Ha adott egy  $x_1, \dots, x_n$  tapasztalati minta, akkor az adatokban lévő nemstacionárius komponens eltüntetésére alkalmas simítási eljárás lehet (nem ez az egyetlen) a *mozgóátlagolás*. Például ha az adataink negyedévesek, akkor érdemes 4 lépésben átlagokat számítani:  $\tilde{x}_t = \frac{x_t + x_{t+1} + x_{t+2} + x_{t+3}}{4}$ ,  $t = 1, 2, \dots, n - 3$ . A mozgóátlagolással az idősor rövidebb lesz, adatokat veszítünk.

## Eredmények az autokorreláció becsléséről

Legyen  $X_1, \dots, X_n$  minta egy stacionárius folyamatból, melynek várható értéke  $\mu$ ,

autokovariancia függvénye  $R(h)$  és autokorreláció függvénye pedig  $r(h)$ . Tekintsük a következő becsléseket:

- $\mu$  becslése:  $\bar{X}_n = \frac{X_1 + \dots + X_n}{n}$ ;
- $R(h)$  becslése:  $\hat{R}(h) = \frac{1}{n} \sum_{t=1}^{n-|h|} (X_{t+|h|} - \bar{X}_n)(X_t - \bar{X}_n)$ , ahol  $|h| < n$  egész;
- $r(h)$  becslése:  $\hat{r}(h) = \frac{\hat{R}(h)}{\hat{R}(0)}$ , ahol  $h = -(n-1), \dots, -1, 0, \dots, n-1$ .

*Megjegyzés.* Az autokovariancia becslésére több statisztika is használható, lásd az előadásjegyzet 4. részét, amely azok statisztikai tulajdonságait is tartalmazza.

Vezessük be a következő jelöléseket:

- $\mathbf{r}(h) = (r(1), \dots, r(h))^T$
- $\hat{\mathbf{r}}(h) = (\hat{r}(1), \dots, \hat{r}(h))^T$
- $\mathbf{0}_h$ :  $h$  hosszú vektor 0 elemekkel
- $\mathbf{I}_h$ :  $h \times h$  méretű egységmátrix

*Tétel. Bartlett-tétel.* Legyen  $X_t$  lineáris folyamat,  $\sum_{j=-\infty}^{\infty} \beta_j^2 |j| < \infty$ . Ekkor

$(\frac{1}{n} \mathbf{W})^{-\frac{1}{2}} (\hat{\mathbf{r}}(h) - \mathbf{r}(h)) \xrightarrow[n \rightarrow \infty]{d} N_h(\mathbf{0}_h, \mathbf{I}_h)$ , ahol  $\mathbf{W}$  az ún. Bartlett-féle mátrix, melynek elemei:  $[\mathbf{W}]_{i,j} = \sum_{k=-\infty}^{\infty} [r(k+i)r(k+j) + r(k-i)r(k+j) + 2r(i)r(j)r^2(k) - 2r(i)r(k)r(k+j) - 2r(j)r(k)r(k+i)]$ .

*Megjegyzés.* Az előző tétel állítását kissé pongyolán, de könnyebben érthetően úgy is írhatjuk, hogy  $\hat{\mathbf{r}}(h) \approx N_h(\mathbf{r}(h), \frac{1}{n} \mathbf{W})$ .

*Következmény.* Amennyiben  $X_1, \dots, X_n$  egy fehér zaj folyamatból származó minta, akkor  $\hat{\mathbf{r}}(h) \approx N_h(\mathbf{0}_h, \frac{1}{n})$ , ezáltal közös  $1 - \alpha$  megbízhatóságú konfidenciaintervallum készíthető az egyes autokorrelációkra:  $0 \pm \frac{\Phi^{-1}(1-\frac{\alpha}{2})}{\sqrt{n}}$ .

*Megjegyzés.* Ha az előző következményben  $\alpha = 0.05$ , akkor közelítőleg a  $[-\frac{2}{\sqrt{n}}; \frac{2}{\sqrt{n}}]$  intervallumbecslés adódik. Amikor  $\mathbf{R}$  segítségével egy idősor autokorreláció függvényét elkészítjük az acf függvény segítségével, akkor a két szaggatott kék vonal a  $\pm \frac{2}{\sqrt{n}}$  értéknek felel meg. Most pedig következnek az a próba, amihez az eddigi előkészítés szükséges volt – legyen  $\alpha$  az elsőfajú hiba valószínűségének előre rögzített értéke:

$H_0$ : a minta autokorrelálatlan folyamatból származik

$H_1$ : legalább az egyik autokorreláció nem 0

Próbastatisztika:  $\mathbf{T}(\mathbf{X}) = \hat{\mathbf{r}}(n-1)$ , ami egy  $n-1$  elemű vektor

Elfogadási tartomány:  $\mathcal{X}_e = \left\{ \mathbf{X} : \text{minden } 1 \leq i \leq n-1 \text{-re } |\hat{r}_i| \leq \frac{\Phi^{-1}(1-\frac{\alpha}{2})}{\sqrt{n}} \right\}$

Tehát ha valamelyik tapasztalati autokorrelációra azt találjuk, hogy annak abszolút értéke meghaladja a  $\frac{\Phi^{-1}(1-\frac{\alpha}{2})}{\sqrt{n}}$  értéket, akkor a minta  $100 \cdot (1 - \alpha)\%$ -os megbízhatósággal nem autokorrelálatlan folyamatból származik. Ennél rendszerint többet is látunk, a belső "sáv"-on kívül eső autokorrelációk arra is utalnak, milyen jellegű nemstacionaritással szembesülünk, illetve milyen idősor modellel érdemes megpróbálni magyarázni

az adatainkat.

## Idősorok "illeszkedésvizsgálata"

A modellező fő célja az, hogy egy adott minta (tapasztalati idősor) esetén kiválassza azt a modellt, amelyik legjobban illeszkedik az adataira. Ez gyakran meglehetősen nehéz feladat. Az idősor modellek túlnyomó többsége valamilyen fehér zaj folyamatból (amit innovációnak is szokás hívni, és gyakran megfigyelési, mérési 'hiba'-ként vagy egyéb véletlen hatások összességéként tekintenek rá) indulnak ki. Az adott idősor modell illeszkedését úgy szokás megvizsgálni, hogy az illesztés – paraméterek becslése – után visszabecsüljük az innovációkat, majd megnézzük, hogy ezek vajon fehér zaj folyamatot követnek-e. Amennyiben a visszabecsült innovációk, más néven reziduálisok esetén *nem* vehető el, hogy fehér zaj folyamatból származnak, akkor az adott idősor modell alkalmazása ellen *nem* találtunk statisztikai bizonyítékot.

Jellemzően mik tudják elrontani a 'fehér zaj'-ságot:

- autokorreláció – a reziduálisok nem autokorrelálatlanok
- heteroszkedaszticitás – a reziduálisok szórása időben változik ( $\longleftrightarrow$  homoszkedaszticitás: a szórás időben konstans)

**Próbák annak ellenőrzésére, hogy egy minta független fehér zajból származik-e:**

a.) A minta autokorreláció függvény *pontonként* egyenlő-e 0-val. A próba leírásáért lásd az előző fejezetet.

Amikor  $\mathbf{R}$  segítségével egy idősor autokorreláció függvényét elkészítjük az acf függvény segítségével, akkor a két szaggatott kék vonal a  $\pm \frac{2}{\sqrt{n}}$  értéknek felel meg. Az alábbi esetekben döntünk amellett, hogy a minta NEM fehér zajból származik:

- az egyik autokorreláció nagyon kiugrik, "sokkal" a kék sávon kívül van. Mi az a "sok": az adott autokorreláció abszolút értéke legalább akkora, mint a sáv hossza.
- ugyan nincs durván kiugró autokorreláció érték, de viszonylag sok érték van a kék sávon kívül. Hüvelyujjszabály arra, mi minősül viszonylag soknak: ha  $m$  darab autokorrelációt rajzoltunk ki, akkor több, mint  $0,05 \cdot m$  autokorreláció van kicsit a kék sávon kívül. Az  $\mathbf{R}$  alap beállítása az  $m = 40$ , ezen ha legalább 3 érték van kicsit a kék sávon kívül, akkor elvetjük

Ennél rendszerint többet is látunk, a belső "sáv"-on kívül eső autokorrelációk arra is utalnak, milyen jellegű nemstacionaritással szembesülünk, illetve milyen idősor modellel érdemes megpróbálni magyarázni az adatainkat.

b.) Portmanteau-tesztek. Nullhipotézisük: az első néhány (általában 20/30) autokorreláció *együttesen* egyenlő-e 0-val. Azaz ha  $H_0$  nem teljesül, akkor NEM hisszük el, hogy a minta fehér zajból származik. A legfontosabbak ezek közül *Ljung-Box próba*. Próbastatisztika:  $Q_{LB} = n(n+2) \sum_{i=1}^h \frac{\hat{r}(i)}{n-i}$ , ami  $H_0$  esetén  $\chi_h^2$ -hoz tart eloszlásban.

- c.) *Különbség-előjel próba* (difference-sign test). Legyen  $Z_n$  annak a száma, ahányszor a folyamat értéke növekszik, azaz  $Z_n = \sum_{i=2}^n Y_i$ , ahol  $Y_i = I(X_i > X_{i-1})$ ,  $i = 2, 3, \dots, n$ . A próbastatisztika:  $\frac{Z_n - \frac{n-1}{2}}{\sqrt{\frac{n-1}{12}}}$ , ami standard normális eloszlásban a nullhipotézis esetén.
- d.) *Fordulópont próba* (turning point test). Legyen  $Z_n$  a fordulópontok száma a mintában. Az  $x_i$  mintapont fordulópont, amennyiben vagy  $(x_i > x_{i-1} \text{ és } x_i > x_{i+1})$ , vagy  $(x_i < x_{i-1} \text{ és } x_i < x_{i+1})$ . Megmutatható, hogy a  $\frac{Z_n - \frac{2}{3}(n-2)}{\sqrt{\frac{8(n-2)}{45}}}$  próbastatisztika standard normális eloszlásban a nullhipotézis esetén.

**Heterokszedaszticitás próba idősorok esetén:** *Mcleod Li teszt*: a négyzetekre végrehajtott Ljung-Box próba. Nullhipotézis: nincs feltételes heteroszkeszticitás, azaz az idősor nem ARCH/GARCH típusú.

**Definíció.  $m$ -összefüggőség.** Az  $(X_n)_{n \in \mathbb{Z}}$  valószínűségi változó sorozat  $m$ -összefüggő, amennyiben a  $\sigma(\dots, X_{k-1}, X_k)$  és  $\sigma(X_{k+m+1}, X_{k+m+2}, \dots)$   $\sigma$ -algebrák minden  $k \in \mathbb{Z}$ -re függetlenek.

**Megjegyzés.** Az egységgyök nélküli MA( $p$ ) folyamat  $p$ -összefüggő.

**Tétel. Centrális határeloszlás-tétel  $m$ -összefüggőség esetén.**

Legyen  $X_1, X_2, \dots$ ,  $m$ -összefüggő, gyengén stationárius valószínűségi változó sorozat,

$$\sigma_m^2 := D^2 X_1 + 2 \sum_{k=1}^m \text{cov}(X_1, X_{1+k}). \quad \text{Ekkor } \frac{\sum_{i=1}^n (X_i - EX_i)}{\sqrt{n\sigma_m}} \xrightarrow{d} N(0; 1).$$

## ARMA folyamatok

**Definíció. Visszaléptetés operátor (backshift operator).**

$$B : L_2(\Omega) \rightarrow L_2(\Omega), \quad BX_t = X_{t-1}$$

**Állítás.** A fenti  $B$  operátor

- iterálható:  $B^k X_t = X_{t-k}$ ,  $k \in \mathbb{Z}_+$ ;
- invertálható:  $B^{-1} X_t = X_{t+1}$ ;
- unitér.

**Definíció. ARMA folyamat.**  $X_t = \underbrace{\sum_{i=1}^p \alpha_i X_{t-i}}_{\text{AR}(p) \text{ rész}} + \underbrace{\sum_{j=0}^q \beta_j \varepsilon_{t-j}}_{\text{MA}(q) \text{ rész}}$ , ahol  $p, q$  pozitív egész

(nevük: *rend*);  $\alpha_i, \beta_j \geq 0$  valós számok;  $\varepsilon_t \sim IVN(0, \sigma^2)$ .

**Megjegyzés.** ARMA: autoregresszív mozgóátlag (autoregressive moving average)

**Megjegyzés.** Az ARMA folyamat másik alakja:  $\sum_{i=0}^p \tilde{\alpha}_i X_{t-i} = \sum_{j=0}^q \beta_j \varepsilon_{t-j}$ , ahol  $\tilde{\alpha}_0 = 1$  és  $\tilde{\alpha}_i = -\alpha_i$  ( $i = 1, \dots, p$ ).

**Definíció. Kauzalitás.** Az ARMA( $p, q$ ) folyamat kauzális (vagy okozati), ha léteznek olyan  $\psi_i$ ,  $i \in \mathbb{Z}$  konstansok, amikre  $\sum_{i=1}^{\infty} |\psi_i| < \infty$  és  $X_t = \sum_{i=1}^{\infty} \psi_i \varepsilon_{t-i} \quad \forall t$ -re.

**Megjegyzés.** Az okozatiság a következőket jelenti:

- az ARMA "egyenletnek" létezik "megoldása";
- az ARMA folyamatnak létezik MA( $\infty$ ) alakja.

**Definíció. Invertálhatóság.** Az ARMA( $p, q$ ) folyamat invertálható, ha léteznek olyan  $\pi_i$ ,  $i \in \mathbb{Z}$  konstansok, amikre  $\sum_{i=1}^{\infty} |\pi_i| < \infty$  és  $\varepsilon_t = \sum_{i=1}^{\infty} \pi_i X_{t-i} \quad \forall t$ -re.

**Megjegyzés.** Az invertálhatóság helyett azt is szokás mondani, hogy a folyamatnak van AR( $\infty$ ) alakja.

**Definíció. ARMA folyamat karakterisztikus polinomjai:**  $P(x) = \sum_{i=0}^p \tilde{\alpha}_i x^{p-i}$ ,

$$\tilde{P}(x) = \sum_{i=0}^p \tilde{\alpha}_i x^i, \quad Q(x) = \sum_{i=0}^q \beta_i x^i.$$

**Állítás.**  $P(x) = x^p \cdot \tilde{P}\left(\frac{1}{x}\right)$

**Állítás.**  $P(x)$  gyökei az egységkörön belül vannak  $\iff \tilde{P}(x)$  gyökei az egységkörön kívül vannak

**Tétel. Az ARMA folyamat "megoldása" és "inverze".**

- Ha  $P(x)$  gyökei az egységkörön belül vannak, akkor a folyamatnak létezik stationárius megoldása;
- Ha  $Q(x)$  gyökei az egységkörön kívül vannak, akkor a folyamatnak létezik inverze.

**Következmény.** Az  $X_t = \alpha X_{t-1} + \varepsilon_t$  AR(1) folyamat stationárius  $\iff |\alpha| < 1$

**Tétel. Az ARMA folyamat spektrális sűrűségfüggvénye:**  $f(x) = \frac{\sigma^2}{2\pi} \left| \frac{Q(e^{ix})}{P(e^{ix})} \right|^2$

Eddig jelöléseinkkel az ARMA folyamat a következő operátoros alakba írható:  $\tilde{P}(B)X_t = Q(B)\varepsilon_t$ . Ezt már ki tudjuk fejteni az ARMA folyamatra, illetve a fehér zajra is:

- $X_t = [\tilde{P}(B)]^{-1} Q(B)\varepsilon_t$
- $\varepsilon_t = [Q(B)]^{-1} \tilde{P}(B)X_t$

Az persze nem triviális, hogy a fenti operátorinverzeket, majd az operátorszorzatokat hogyan állítsuk elő, ezen a ponton segítségül kell hívni a homogén lineáris differencia-egyenletek elméletét. Legyen célunk a fenti  $X_t$  előállítás explicit megadása, a másik hasonlóan megy. Jelölje  $S(x) = \sum_{i=0}^{\infty} s_i x^i$  azt a polinomot, amire  $S(B) = [\tilde{P}(B)]^{-1} Q(B)$ .

Ebben az inverz úgy kapható meg, hogy keressük azt a  $T(x) = \sum_{i=0}^{\infty} t_i x^i$  polinomot, amire  $T(x)\tilde{P}(x) = 1$ . Ezen a ponton rendszerint abba futunk bele, hogy az  $s_i$  együtt-

hatókra egy rekurzió (differenciaegyenlet) adódik, amit meg kellene oldani. Tekintsük a következő homogén differenciaegyenletet:

$$s_t + \gamma_1 s_{t-1} + \dots + \gamma_k s_{t-k} = 0,$$

ahol

- $k \leq t \in \mathbb{Z}$ ;
- $\gamma_1, \dots, \gamma_k \in \mathbb{Z}$ ;  $\gamma_i \neq 0 \forall i$ -re;
- adottak  $s_0, s_1, \dots, s_{k-1}$  kezdeti értékek.

Mi a gyakorlaton "kézzel" legfeljebb másodrendű differenciaegyenleteket fogunk megoldani. Ezekről szólnak az alábbi állítások.

**Állítás.** Az  $s_t + \gamma_1 s_{t-1} = (1 - \xi^{-1}B)s_t = 0$  elsőrendű homogén lineáris differenciaegyenlet általános megoldása:  $s_t = s_0 \xi^{-t}$ .

**Állítás.** Az  $s_t + \gamma_1 s_{t-1} + \gamma_2 s_{t-2} = (1 - \xi_1^{-1}B)(1 - \xi_2^{-1}B)s_t = 0$  másodrendű homogén lineáris differenciaegyenlet általános megoldása:

1. eset:  $\xi_1 \neq \xi_2$  valósak  $\rightsquigarrow s_t = c_1 \xi_1^{-t} + c_2 \xi_2^{-t}$ , ahol  $c_1$  és  $c_2$  valós konstansok a kezdeti értékek felhasználásával, a  $\begin{cases} c_1 + c_2 & = s_0 \\ c_1 \xi_1^{-1} + c_2 \xi_2^{-1} & = s_1 \end{cases}$  egyenletrendszer megoldásából adódnak (a többinél hasonlóan).
2. eset:  $\xi_1 = \xi_2$  valósak  $\rightsquigarrow s_t = (c_1 + c_2 t) \xi_1^{-t}$ , ahol  $c_1$  és  $c_2$  valós konstansok a kezdeti értékek felhasználásával adódnak.
3. eset:  $\xi_1 \neq \xi_2$  komplexek  $\rightsquigarrow s_t = c_1 \xi_1^{-t} + c_2 \xi_2^{-t}$ , ahol  $c_1$  és  $c_2$  komplex konstansok a kezdeti értékek felhasználásával adódnak. Az általános megoldás másképp is felírható, mivel algebrából megtanultuk, hogy  $\xi_2 = \bar{\xi}_1$ . Felhasználva a  $\xi_1 = de^{i\theta}$  exponenciális alakot,  $s_t = ad^{-t} \cos(\theta t + b)$ , ahol  $a$  és  $b$  a kezdeti értékek felhasználásával adódó valós konstansok.

Az ARMA modellek kiválasztásánál segítségünkre lehetnek azok tulajdonságai:

Modell	$R(h)$ autokorreláció fv.	$r(h)$ parciális autokorreláció fv.
AR( $p$ )	tart 0-hoz, ha $ h  \rightarrow \infty$	nem 0, ha $ h  \leq p$ ; egyébként 0
MA( $q$ )	nem 0, ha $ h  \leq q$ ; egyébként 0	tart 0-hoz, ha $ h  \rightarrow \infty$
ARMA( $p, q$ )	tart 0-hoz, ha $ h  \rightarrow \infty$ , az első $q$ érték után kezdődik a konvergencia	tart 0-hoz, ha $ h  \rightarrow \infty$ , az első $p$ érték után kezdődik a konvergencia

**Modellválasztás:** a "legjobb" ARMA( $p, q$ ) folyamat kiválasztása. Lépései:

1. Rendek ( $p, q$ ) kiválasztása.

Ebben segítségünkre vannak az alábbi információs kritériumok:

- **Akaike-féle információs kritérium:**  $AIC = 2k - 2 \log \hat{L}$ , ahol
  - $k$ : a becsülendő paraméterek száma
  - $\hat{L}$  a likelihood-függvény értéke akkor, ha az ML-beclést használjuk (normális eloszlású hibáknál ez megegyezik a legkisebb négyzetes becléssel)
Minél kisebb, annál jobb.
- **Bayes-féle információs kritérium:**  $BIC = \log n \cdot k - 2 \log \hat{L} \rightsquigarrow$  minél kisebb, annál jobb

A tapasztalati autokovariancia függvény alapján a fenti táblázat segíthet a megfelelő rend kiválasztásában. Az információs kritériumokon alapuló döntés rendszerint jobb.

2. Ismeretlen paraméterek becslése.

A klasszikus módszerek most is használhatók: momentum módszer (az autokovarianciákból adódó Yule-Walker egyenletrendszer), ML-módszer, legkisebb négyzetek módszere. Az ML-módszer általában a legjobb, de mivel idősoros modelleknél optimalizálás rutinnal számolódik, ezért rendszerint a leglassabb is egyben.

Becslés után meg kell nézni, hogy az együtthatók szignifikánsak-e. Minden számítógépes programcsomag meg szokta adni a paraméterek  $\hat{\vartheta}$  pontbecslését és ezek  $\widehat{D}(\hat{\vartheta})$  standard hibáját. Hüvelykujszabály arra, hogy a  $\vartheta$  paraméter szignifikáns-e, azaz állíthatjuk-e, hogy eltér-e nullától: a 0 benne van-e a  $\hat{\vartheta} \pm 2 \cdot \widehat{D}(\hat{\vartheta})$  intervallumban. Ha nincs benne a 0, akkor szignifikáns.

**Modelldiagnosztika:** miután illesztettünk egy modellt, meg kell nézni, teljesülnek-e az adott idősormodell definíciójának feltételei. ARMA modellek esetén ez annak vizsgálatát jelenti, hogy a reziduálisok származhatnak-e fehér zajból. Az alábbi tesztek szokás rendszerint végrehajtani:

- Empirikus autokorreláció függvényben a sávon kívüli értékek vizsgálata
- Ljung-Box próba vagy egy általánosítása
- Heteroszkedaszticitás teszt – amennyiben azt kapjuk, hogy az idősor nem homoszkedasztikus, akkor a reziduálisokra GARCH modellt illesztünk

**Megjegyzés.** A modelldiagnosztikába néha bele szokták venni az együtthatók szignifikanciájának vizsgálatát is.

Amennyiben azt kapjuk, hogy az ARMA folyamat nem illeszkedik megfelelően, számos további teendőnk lehet:

- Van-e trend/szezonálitás az idősorban (ezek kiszűrésével illik kezdeni az elemzést, lásd a következő fejezetet)
- Próbálkozás másik idősormodelllel

Végül kimondjuk az idősorelmélet egyik legfontosabb tételét, ami megmutatja, miért van kiemelt szerepe az MA( $\infty$ ) modelleszaládnak. A tételbeli 'négyzetes előrejelezhetőség' és a 'determinisztikusság' a viszonylag hosszadalmas előkészítés igénye miatt nem lesz definiálva, ld. például a Brockwell–Davis könyv 2.6. fejezetét és az előtte lévő fejezete(ke)t további részletekért.

**Tétel. Wold-felbontás.** Tetszőleges  $X_t$  stacionárius folyamat felírható a következő alakba:  $X_t = \sum_{i=0}^{\infty} \psi_i \varepsilon_{t-i} + V_t$ , ahol

- $\psi_0 = 1, \sum_{i=0}^{\infty} \psi_i^2 < \infty$ ;
- $\varepsilon_t \sim WN(0, \sigma^2)$ ;
- $V_t$  'determinisztikus' folyamat;
- $\text{cov}(\varepsilon_t, V_s) = 0 \forall s, t$ -re;

- $\varepsilon_t$  és  $V_t$  'négyzetesen előrejelezhető' folyamatok.

## Nevezetes nemlineáris folyamatok

**Definíció. GARCH folyamat.**  $(X_t)_{t \in \mathbb{Z}}$  GARCH( $p, q$ ) folyamat, ha

$$X_t = \sigma_t \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i X_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

$\sigma_t^2$  a folyamat időben változó szórásnégyzete,  $\varepsilon_t \sim IVN(0, 1)$ ,  $E\varepsilon_t^4 < \infty$ , továbbá  $\alpha_0 > 0$ ,  $\alpha_i \geq 0$ ,  $\beta_j \geq 0$  minden  $i$  és  $j$  esetén.

Speciálisan, ha  $\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i X_{t-i}^2$ , akkor az  $X_t$  folyamat neve: ARCH( $p$ ) folyamat

**Megjegyzés.** A folyamatot  $X_t = \sqrt{\alpha_0 + \sum_{i=1}^p \alpha_i X_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2} \cdot \varepsilon_t$  alakba is írhatjuk.

**Megjegyzés.** A folyamat elnevezése: GARCH = generalised autoregressive conditional heteroskedastic, azaz magyarul általánosított autoregresszív, feltételesen heteroszkedasztikus.

**Állítás.** A GARCH( $p, q$ ) folyamat (NEM független) fehér zaj.

**Tétel. A GARCH folyamat gyenge stacionaritása.**

- Ha  $\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j < 1$ , akkor a GARCH( $p, q$ ) folyamatnak létezik gyengén stacionárius megoldása ("megoldás":  $X_t$  folyamat MA( $\infty$ ) alakja).
- Ha a GARCH( $p, q$ ) folyamatnak létezik gyengén stacionárius megoldása és  $\alpha_0 > 0$ , akkor  $\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j < 1$ .

A GARCH folyamatból generált minta jellemzői:

- Az adatok nem korreláltak, és a szórás változik az idővel;
- Az adatok eloszlása vastag szélű;
- A négyzetek és az abszolútértékek erősen korreláltak;
- A kiugró értékek klaszterekben jelennek meg.

Amennyiben egy tapasztalati mintánál a fenti jellemzőket figyeljük meg, érdemes megpróbálkozni GARCH folyamattal modellezni. Ezek a tulajdonságok a pénzügyi adatsoroknál gyakran megfigyelhetők (például részvényárfolyamok, valutaárfolyamok loghozamainál).

**Megjegyzés.** Amennyiben valamilyen heteroszkedasztikus folyamattal szeretnénk modellezni a megfigyeléseket, akkor nagyon gyakran megfelelő választás a viszonylag egyszerű GARCH(1,1) modellt illeszteni.

**Definíció. Általános bilineáris folyamat.**  $(X_t)_{t \in \mathbb{Z}}$  BL( $p, q, P, Q$ ) folyamat, ha

$$X_t + \underbrace{\sum_{i=0}^p a_i X_{t-i}}_{AR \text{ komponens}} = \underbrace{\varepsilon_t}_{zaj} + \underbrace{\sum_{j=0}^q b_j \cdot \varepsilon_{t-j}}_{MA \text{ komponens}} + \sum_{i=1}^P \sum_{j=1}^Q c_{ij} X_{t-i} \varepsilon_{t-j},$$

ahol  $\varepsilon_t \sim IVN(0, 1)$ , az  $a_i, b_j, c_{i,j}$  együtthatók valós konstansok és a pozitív egész  $p, q, P, Q$  számok a folyamat rendjei.

## Sztochasztikus rekurziós egyenletek

Ennek a fejezetnek a fő eredménye azon tétel ismertetése, amely bemutatja, milyen elégséges feltétel esetén van egy, számos nevezetes idősor modellt magába foglaló idősormodell-családnak erősen stacionárius "megoldása", és ez a "megoldás" miként állítható elő.

**Definíció. Sztochasztikus rekurziós egyenlet.** Az

$$\mathbf{X}_t = \mathbf{A}_t \mathbf{X}_{t-1} + \mathbf{B}_t, \quad t = 0, 1, \dots \quad (1)$$

egyenletet sztochasztikus rekurziós egyenletnek hívjuk (SRE), ha  $\mathbf{A}_t$  véletlen  $d \times d$ -s mátrix,  $\mathbf{B}_t$  véletlen  $d$ -dimenziós vektor, továbbá  $(\mathbf{A}_t, \mathbf{B}_t)$  i.i.d.

**Megjegyzés.** Az ARMA, a GARCH és a BL folyamatok felírhatók SRE alakban.

A továbbiakban jelölje  $\|\cdot\|$  a 2-es vektor/mátrixnormát, és  $\log^+(x) := \max(\log(x), 0)$ .

**Definíció. Az  $\mathbf{A}_t$  véletlen mátrixsorozat Ljapunov-exponense.**

$$\Lambda := \inf_{t \in \mathbb{Z}_+} \left\{ \frac{1}{t} \cdot E \log \|\mathbf{A}_1 \cdot \dots \cdot \mathbf{A}_t\| \right\}$$

**Tétel.** Tegyük fel, hogy  $E \log^+ \|\mathbf{A}_1\| < \infty$ ,  $E \log^+ |\mathbf{B}_1| < \infty$  és  $\Lambda < 0$ . Ekkor

$$\mathbf{X}_n = \mathbf{B}_n + \sum_{k=1}^{\infty} \mathbf{A}_n \cdot \dots \cdot \mathbf{A}_{n-k+1} \mathbf{B}_{n-k}$$

1 valószínűséggel konvergens, és ez az egyértelmű, erősen stacionárius, oksági megoldása az (1) sztochasztikus rekurziós egyenletnek.

**Megjegyzés.** Ha  $d = 1$ , akkor  $\Lambda < 0 \iff E \log |A_1| < 0$

Most néhány eredmény következik analízisből, amikre néhány példa megoldásához szükség lesz.

**Definíció. Euler-féle gamma-függvény:**  $\Gamma(t) = \int_0^{\infty} x^{t-1} e^{-x} dx, \quad t \in \mathbb{R}$

**Állítás.**

- Néhány nevezetes érték:  $\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi} \quad \Gamma(n) = (n-1)!, \quad n = 1, 2, \dots$

- Az Euler-féle gamma-függvény abszolút konvergens (mint paraméteres integrál), ezért "be lehet deriválni" az integráljel mögé:

$$\Gamma'(t) = \frac{d}{dt}\Gamma(t) = \int_0^{\infty} \frac{d}{dt}e^{-x}x^{t-1} dx = \int_0^{\infty} e^{-x} \cdot \log x \cdot x^{t-1} dx$$

**Definíció. Euler-féle digamma-függvény:**  $\psi(t) = \frac{d}{dt} \log \Gamma(t) = \frac{\Gamma'(t)}{\Gamma(t)}$ ,  $t \in \mathbb{R}$

A következő tétel arról szól, hogyan lehet a digamma-függvényt tetszőleges 1-nél kisebb pozitív racionális szám esetén viszonylag könnyen, zárt alakban kiszámítani. Érdekeség, hogy ilyen tétel nem ismert az egyszerűbb gamma-függvény esetén. A továbbiakban  $\gamma \approx 0,577$  jelöli az Euler-konstansot.

**Tétel. Gauss digamma-tétele.** Legyen  $r, m \in \mathbb{Z}_+$ ,  $r < m$ . Ekkor

$$\psi\left(\frac{r}{m}\right) = -\gamma - \log(2m) - \frac{\pi}{2} \operatorname{ctg}\left(\frac{r\pi}{m}\right) + 2 \sum_{n=1}^{\lfloor \frac{m-1}{2} \rfloor} \cos\left(\frac{2\pi nr}{m}\right) \log \sin\left(\frac{\pi n}{m}\right).$$

Néhány nevezetes érték:  $\psi\left(\frac{1}{2}\right) = -\gamma - 2 \log 2$ ,  $\psi(1) = -\gamma$

### Idősorok előrejelzése

Előrejelzési feladat: legyen  $(X_n)_{n \in \mathbb{Z}}$  stacionárius folyamat  $\mu$  várható értékkel és  $R(h)$  autokovariancia függvényvel. Célunk a folyamat első  $n$  értéke,  $X_n, \dots, X_1$  segítségével az ezt követő  $h$  érték,  $X_{n+h}, \dots, X_{n+1}$  meghatározása úgy, hogy a legkisebb négyzetes értelemben vett hiba a lehető legkisebb legyen.

Jelölje a legjobb lineáris előrejelzést  $\mathbb{P}_n X_{n+h} := a_0 + a_1 X_n + \dots + a_n X_1$ .

**Állítás. A legjobb lineáris előrejelzés operátor tulajdonságai.**

- A legjobb lineáris előrejelzés együtthatói kielégítik a következő egyenleteket:  
 $E(X_{n+h} - \mathbb{P}_n X_{n+h}) = 0$   
 $E[(X_{n+h} - \mathbb{P}_n X_{n+h})X_{n+1-j}] = 0 \quad j = 1, \dots, n$
- a legjobb lineáris előrejelzés együtthatói kielégítik a következő egyenletrendszer:  
 $\mathbf{\Gamma}_n \mathbf{a}_n = \mathbf{R}_n(h)$ , ahol
  - $\mathbf{\Gamma}_n = [R(i-j)]_{i,j=1}^n$ ;
  - $\mathbf{a}_n = (a_1, \dots, a_n)^T$ ;
  - $\mathbf{R}_n(h) = (R(h), R(h+1), \dots, R(h+n-1))^T$ .
- Az előrejelzés  $\mathbb{P}_n X_{n+h} = \mu + \sum_{i=1}^n a_i (X_{n+1-i} - \mu)$  alakba írható, így a feladatok elején  $\mu = 0$  feltehető, majd ezzel a képlettel megkapható az előrejelzés;
- Az előrejelzés legkisebb négyzetes hibája  $R(0) - \mathbf{a}_n^T \mathbf{R}_n(h)$ .

**Állítás.**  $R(0) > 0$  és  $R(h) \xrightarrow{h \rightarrow \infty} 0$  esetén a fenti  $\mathbf{\Gamma}_n$  invertálható, így az  $a_i$  együtthatók  $\mathbf{a}_n = \mathbf{\Gamma}_n^{-1} \mathbf{R}_n(h)$  módon számolhatók.

**Az általános előrejelzési operátor.**

Legyen  $\mathbf{W} = (W_n, \dots, W_1)^T$  véletlen vektor,  $Y$  valószínűségi változó, mindannyian véges szórással/szórás mátrixszal. Jelölje  $\mathbf{\Gamma} = \operatorname{cov}(\mathbf{W}) = \Sigma(\mathbf{W})$  a kovarianciamátrixot.

Célunk:  $\mathbf{W}$  segítségével  $Y$  legkisebb négyzetes lineáris előrejelzésének (becslésének) előállítás.

Jelölje az előrejelzési operátort  $\mathbb{P}(\bullet | \mathbf{W}) : L_2(\Omega) \rightarrow L_2(\Omega)$ , amit lineáris alakban keresünk:  $\mathbb{P}(Y | \mathbf{W}) = a_0 + \mathbf{a}_n^T \mathbf{W}$ , ahol  $a_0$  és  $\mathbf{a}_n = (a_1, \dots, a_n)^T$  a becslendő értékek.

**Állítás. Az általános legjobb lineáris előrejelzés operátor tulajdonságai.**

Legyenek  $\alpha_1, \dots, \alpha_n, \beta$  tetszőleges valós számok és  $Z$  tetszőleges véges szórású valószínűségi változó. Ekkor

- $\mathbb{P}(Y | \mathbf{W}) = EY + \mathbf{a}_n^T (\mathbf{W} - E\mathbf{W})$ , ahol  $\mathbf{\Gamma} \mathbf{a}_n = \operatorname{cov}(Y, \mathbf{W})$ ;
- $E(Y - \mathbb{P}(Y | \mathbf{W})) = 0$   
 $E[(Y - \mathbb{P}(Y | \mathbf{W}))\mathbf{W}] = 0$ ;
- $MSE = E[(Y - \mathbb{P}(Y | \mathbf{W}))^2] = D^2 Y - \mathbf{a}_n^T \operatorname{cov}(Y, \mathbf{W})$ ;
- $\mathbb{P}(\alpha_1 Y + \alpha_2 Z + \beta | \mathbf{W}) = \alpha_1 \mathbb{P}(Y | \mathbf{W}) + \alpha_2 \mathbb{P}(Z | \mathbf{W}) + \beta$ ;
- $\mathbb{P}\left(\sum_{i=1}^n \alpha_i W_i + \beta \mid \mathbf{W}\right) = \sum_{i=1}^n \alpha_i W_i + \beta$ ;
- ha  $\operatorname{cov}(Y, \mathbf{W}) = \mathbf{0}$ , akkor  $\mathbb{P}(Y | \mathbf{W}) = EY$ .

**Megjegyzés.**  $\mathbb{P}$  általános előrejelzési operátor kapcsolata a  $\mathbb{P}_n$  operátorral:  $\mathbb{P}_n(X_{n+h}) = \mathbb{P}(X_{n+h} | \mathbf{X}_n)$ , ahol  $\mathbf{X}_n = (X_n, \dots, X_1)^T$ .

**Megjegyzés.** A fenti állítás a.) részéből következik, hogy  $\mathbf{a}_n^T$  ismeretében már meghatározható az  $a_0$  konstans:  $a_0 = EY - \mathbf{a}_n^T E\mathbf{W}$ . Speciális esetben, amennyiben a  $\mathbb{P}_n$  operátorral dolgozunk, akkor  $a_0 = \mu \cdot \left(1 - \sum_{i=1}^n a_i\right)$ .

**Megjegyzés.** A fenti állítás b.) részéből látszik, hogy a legjobb lineáris legkisebb négyzetes becslés torzítatlan.

**Megjegyzés.** Az általános előrejelzési operátor segítségével módunkban áll hiányzó vagy hibásnak vélt adatok értékét megbecsülni.

### Nemstacionárius idősorok modellezése

**Definíció. Lag-1 differencia operátor.**  $\nabla = 1 - B$ , ahol  $B$  a visszaléptetés operátor.

**Definíció. Lag-d differencia operátor.**  $\nabla_d = 1 - B^d$ .

Ezáltal  $\nabla X_t = X_t - X_{t-1}$  és  $\nabla_d X_t = X_t - X_{t-d}$ . A differencia operátort tetszőleges pozitív egész hatványra lehet emelni, ekkor  $\nabla^m X_t = \nabla^{m-1}(X_t - X_{t-1})$ , ami tovább iterálható.

**Definíció. ARIMA modell.** Az  $X_t$  folyamat ARIMA( $p, d, q$ ) folyamatot követ, amennyiben  $Y_t = (1 - B)^d X_t$  folyamat ARMA( $p, q$ ) folyamatból származik.

**Megjegyzés.** Az ARIMA-ban az I betű az 'Integrated' angol szó rövidítése (integrált).

ARIMA modelleknél az integráltságot kifejező  $d$  paraméter értékének megállapításában az ún. **egységgyök tesztek** segítenek. Amennyiben a modell  $P(x)$  karakterisztikus

polinomjának van egységgyöke (az egyik gyökének 1 az abszolútértéke), akkor a folyamat nem lesz stacionárius. Az egységgyök tesztek olyan nem-stacionaritást vizsgálnak, amely differencia-képzéssel eltüntethető.

A leggyakrabban használt egységgyök teszt a **kiterjesztett Dickey–Fuller próba**. Működésének megértéséhez tekintsük először legegyszerűbb változatát.

Legyen  $X_t = \alpha X_{t-1} + \varepsilon_t$ ,  $\varepsilon_t \sim GWN(0, \sigma^2)$  AR(1) folyamat. Tudjuk, hogy  $\alpha = 1$  esetén ez éppen a véletlen bolyongás, ami nem stacionárius és  $X_t = \sum_{i=1}^t \varepsilon_i$  alakba írható;

$|\alpha| < 1$  esetén pedig stacionárius. Az AR(1) egyenlet átírható a  $\nabla X_t = \phi X_{t-1} + \varepsilon_t$  alakba, ahol  $\phi = \alpha - 1$ . A teszt hipotézisei:  $H_0 : \alpha = 1$  és  $H_1 : |\alpha| < 1$ , tehát az ellenhipotézis azt állítja, hogy stacionárius a folyamat; a nullhipotézist pedig azt, hogy ugyan NEM stacionárius, de differencia képzésével stacionáriussá tehető. Végrehajtásához írjuk fel  $\nabla X_t$  lineáris regresszióját  $X_{t-1}$  segítségével, a próbastatisztika pedig legyen a regressziós együttható standardizáltja:  $\frac{\hat{\alpha}-1}{D(\hat{\alpha}-1)}$ . A Donsker-tétel segítségével meg lehet mutatni, hogy a nullhipotézis esetén ez a próbastatisztika eloszlásban egy olyan valószínűségi változóhoz tart, aminek kvantiliseit csak szimulációval vagy numerikus approximációval lehet megkapni.

A próba kiterjesztett változata AR( $p$ ) folyamatból indul ki, valamint megengedi  $\mu$  drift és  $\eta t$  trend jelenlétét is a folyamatban:  $X_t = \mu + \eta t + \sum_{j=1}^p \alpha_j X_{t-j} + \varepsilon_t$ . Itt a regresszió

óra alkalmas alak  $\nabla X_t = \mu + \eta t + \phi X_{t-1} + \sum_{j=1}^p \psi_j \nabla X_{t-j} + \varepsilon_t$ , ahol  $\phi = \sum_{j=1}^p \alpha_j - 1$  és

$\psi_j = -\sum_{k=j}^p \alpha_k$ . A nem-stacionaritást most is  $H_0 : \phi = 0$ -val teszteljük, a próbastatisztika itt is a  $\phi$  alkalmas becslése, felhasználva a regressziós együtthatók becslését.

Egységgyök teszt végrehajtásánál a modellező feladata annak meghatározása, hogy mi legyen a  $p$  rend, valamint hogy drift és/vagy trend jelenlétére is számít-e a vizsgált folyamatnál.

**Klasszikus idősor-dekompozíciós modell:**  $X_t = m_t + s_t + Y_t$ , ahol

- $m_t$ : trend komponens – valamilyen szabályosan változó függvény, ami gyakran lineáris vagy négyzetes.
- $s_t$ : szezonális komponens – a rendszeresen ismétlődő, azonos periodicitású és szabályos amplitúdójú, rendszerint rövid távú ingadozásokat tartalmazza. Ha  $d \in \mathbb{Z}$  jelöli a szezonalitást leíró periódusok hosszát, akkor  $s_t = s_{t+d}$  minden  $t$ -re. Feltesszük, hogy  $\sum_{i=1}^d s_i = 0$ . Közgazdasági alkalmazásokban a  $d$  értéke negyedéves adatoknál jellemzően 4, havi adatoknál pedig 12.
- $Y_t$ : véletlen zaj tag, egy olyan stacionárius komponens, amit már valamilyen ismert idősor-moddelllel modellezhetünk. Feltesszük, hogy  $EY_t = 0$ , különben a konstans beolvasztható lenne a trend tagba.

A nemstacionárius idősoroknál a trend hatás kimutatására, illetve eltüntetésére két megközelítést lehet követni:

## 1. Trend becslése

- **Paraméteres:** Alkalmas függvényt illesztünk, ami rendszerint egy polinom szokott lenni, azaz  $m_t = \sum_{i=0}^p c_k t^k$  alakú, a  $c_k$  együtthatókat pedig legkisebb

négyzetek módszerével lehet becsülni. Ezen a ponton kihasználhatjuk, hogy egy ilyen alakú regressziós modell a lineáris modell speciális esete.

A paraméteres megközelítés hátránya, hogy feltesszük, a választott függvény a jövőben is jól fogja leírni az idősor dinamikáját, márpedig egy válság vagy akár egy váratlan pozitív esemény hatására erre nincs semmi biztosíték.

- **Nemparaméteres:** a leggyakoribb egy lineáris szűrő alkalmazása, kevésbé gyakori az exponenciális simítás. Egyre népszerűbb az ún. LOESS simítás, ami egy lokális regressziós függvényillesztést takar.

A nemparaméteres megközelítések hátránya, hogy csak lokálisan simítanak, így nem lehet velük közvetlenül előrejelzést készíteni. Amennyiben mégis szükségünk van előrejelzésekre, akkor meg kell próbálni a simított folyamatra valamilyen jól illeszkedő függvényt illeszteni – azonban nem garantált, hogy sikerül ilyen függvényt találnunk.

## 2. Trend eliminálása differenciálással – annyiszor alkalmazzuk a $\nabla$ differencia operátort a folyamatra, amíg el nem tűnik a trend. Például lineáris trend esetén már egyszeres differenciálás is eltünteti a trend komponens.

Most áttekintjük, hogy mennyivel van több dolgunk, amennyiben a szezonális hatásokkal is kezdeni szeretnénk valamit. A nemstacionárius idősoroknál a trend ÉS a szezonális hatás kimutatására, illetve eltüntetésére az alábbi megközelítéseket lehet követni:

### 1. Szezonindexek becslése

Legyen  $x_1, x_2, \dots, x_n$  a tapasztalati mintánk. Először az előzőekben leírt valamilyen paraméteres vagy nemparaméteres módszerrel kiszűrjük az  $\hat{m}_t$  trend hatást, majd az  $x_t - \hat{m}_t$  eltérésekből átlagolással megbecsüljük az egyedi szezonhatásokat. Végül ezek átlagával korrigálunk, hogy az összegük 0 legyen. Tehát a két lépés a szezonhatások számszerűsítésére:

I. Korrigálatlan egyedi szezonindexek becslése (Létrehozunk  $d$  darab halmazt, amelyekbe minden  $d$ -edik eltérést teszünk be, majd az egyes halmazokban lévő számok átlagát számítjuk. Például az első halmazba tartozik az  $1., (d+1)., (2d+1).$  stb. eltérések, a másodikba a  $2., (d+2)., (2d+2).$  stb. eltérések):

$$\tilde{s}_k = \frac{\sum_{i: 1 \leq k+id \leq n} (x_{k+id} - \hat{m}_{k+id})}{\sum_{i: 1 \leq k+id \leq n} 1}, \quad k = 1, 2, \dots, d$$

II. Egyedi szezonindexek korrigálása:  $\hat{s}_k = \tilde{s}_k - \frac{1}{d} \sum_{i=1}^d \tilde{s}_i$ ,  $k = 1, 2, \dots, d$

### 2. Differenciálás – annyiszor alkalmazzuk a $\nabla$ differencia operátort a folyamatra, amíg el nem tűnik a trend. Ezután megnézzük, hogy maradt-e még szezonális a reziduálisokban, és ha igen, akkor alkalmas $d$ -vel alkalmazzuk $\nabla_d$ differencia operátort. A $d$ kiválasztásában segítségünkre lehet a folyamat ábrája, illetve az

ACF/PACF függvények.

- Szűrés – alkalmas lineáris szűrővel a trend és a szezonális hatások együttes eliminálása. Polinomiális trend esetén lehet találni ilyen szűrőt.

Most szintetizáljuk az eddigi ismereteinket! Amennyiben az erős időbeli összefüggőseget mutató tapasztalati mintánkat az időtartományban (time domain, szemben a gyakorisági tartománnyal – frequency domain) szeretnénk modellezni, akkor a következő lépéseket kell követni.

**Az idősor-modellezés fő lépései (Box-Jenkins modellezés):**

- Az idősor ábrázolása vonaldiagrammal
  - ránézásra homogén, hasonlóan kinéző részekre bontani (amelyek elegendő mintaelemet tartalmaznak)
  - kiugró/hibás/hiányzó értékek kezelése: kihagyás/javítás/békén hagyás
- Előzetes transzformáció, például ha exponenciálisan nő az ábra alapján, akkor érdemes logaritmust venni.
- Trend komponens kiszűrése
- Szezonális komponens kiszűrése
- Modell illesztése – lépései:
  - A megfelelő modellcsalád kiválasztása (a gyakorlatunkon ARMA/ARIMA)
  - a legjobb modell kiválasztása a modellcsaládon belül valamelyik információs kritérium alapján, például ARMA(1,1)
  - paraméterbecslés alkalmas módszerrel (momentum, ML-becslés, legkisebb négyzetek)
- Modelldiagnosztika – lépései:
  - becsült együtthatók szignifikánsak-e
  - a modelltől visszszámolt reziduálisok fehér zaj folyamatot követnek-e
  - teljesül-e a homoszkedaszticitás. Amennyiben még heteroszkedasztikusak a reziduálisok, akkor illesszünk rájuk GARCH folyamatot.

Amennyiben az illeszkedés megfelelő, akkor mehetünk tovább, ellenkező esetben ugorjunk vissza az 5. pontra vagy a 2. pontra.
- Előrejelzés: általában ez a végső cél, szeretnénk meglévő adataink alapján az idősor jövőbeli viselkedésére minél jobb jóslást adni.

Számos közgazdasági idősor jól modellezhető a következő definícióban szereplő modellcsalád egy alkalmasan választott tagjával.

**Definíció. SARIMA (szezonális ARIMA) modell.** Az  $X_t$  folyamat SARIMA( $p, d, q$ )  $\times$  ( $P, D, Q$ ) $_s$  folyamatot követ  $s$  periódussal, amennyiben  $Y_t = (1 - B)^d(1 - B^s)^D X_t$  folyamat szezonális ARMA( $p, q$ ) folyamatból származik, azaz a következő alakba írható:  $\tilde{P}(B)\tilde{R}(B^s)Y_t = Q(B)S(B^s)\varepsilon_t$ , ahol

$$\begin{aligned} \bullet \tilde{P}(x) &= 1 - \alpha_1 x - \dots - \alpha_p x^p & \bullet Q(x) &= 1 + \beta_1 x + \dots + \beta_q x^q \\ \bullet \tilde{R}(x) &= 1 - \gamma_1 x - \dots - \gamma_r x^r & \bullet S(x) &= 1 + \delta_1 x + \dots + \delta_Q x^Q \end{aligned}$$

**Idősorok spektrálmélete**

Idősorelemzést két megközelítésben lehet végezni:

- időtartományban (time domain): az idősor autokorrelációs struktúráját ( $R(h)$ ) elemezzük, illetve a parciális autokorrelációt. A Box-Jenkins modellezés erről szól.
- frekvenciatartományban (frequency domain): az idősor spektrumát, spektrális sűrűségfüggvényét elemezzük ( $f(x)$ ). Ez a fejezet ezzel kapcsolatban tartalmaz egy rövid bevezetőt.

A Fourier-elmélet egyik legfontosabb eredménye Carleson tétele, amely kimondja, hogy minden  $L_2$ -beli periodikus függvényt pontonként majdnem mindenütt előállít a Fourier-sora, azaz felírható szinusz–koszinusz hullámok összegeként. Az idősorok spektrálméletében az idősorokat – amik véletlen folyamatok – véletlen amplitúdójú szinusz–koszinusz hullámok összegeként írjuk fel. Egy periodikus függvényt az alábbi mennyiségek jellemeznék:

- $P$  periódus/hullámhossz: egy hullám hossza (mértékegysége az idő)
- $A$  amplitúdó: egy hullám legnagyobb és legkisebb értéke közti különbség fele
- $f = \frac{1}{P}$  frekvencia: egységnyi idő alatt hány periódus megy végbe (mértékegysége: hertz)
- $\omega = 2\pi f$  körfrekvencia

**Definíció.** Legyen  $X_t$  stacionárius folyamat,  $EX_t = 0$ ,  $\sum_{h=-\infty}^{\infty} |R(h)| < \infty$ . Ekkor  $X_t$

**spektrális sűrűségfüggvénye:**  $f(x) = \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} e^{-ihx} R(h)$ ,  $-\infty < x < \infty$ .

**Megjegyzés.** Elég  $[-\pi; \pi]$  intervallumon megnézni, mert periodikus.

**Állítás.** A spektrális sűrűségfüggvény tulajdonságai:

- $f$  páros, azaz  $f(-x) = f(x) \quad \forall x \in \mathbb{R}$  esetén
- $f(x) \geq 0 \quad \forall x \in \mathbb{R}$  esetén
- $R(h) = \int_{-\pi}^{\pi} e^{ihx} f(x) dx$

**Megjegyzés.** A spektrális sűrűségfüggvény (1 valószínűséggel) egyértelmű.

**Megjegyzés.**  $f$  Fourier-együtthatói épp az  $R(h)$  autokovarianciák.

**Állítás.** Az  $f : [-\pi; \pi] \rightarrow \mathbb{R}$  függvény spektrális sűrűségfüggvénye egy gyengén stacionárius folyamatnak  $\iff$

- $f$  páros;
- $f \geq 0$ ;
- $\int_{-\pi}^{\pi} f(x) dx < \infty$ .

**Következmény.**

$R(h)$  abszolút szummábilis függvény autokovariancia függvénye egy gyengén stacionárius folyamatnak  $\iff$

- $R$  páros;
- $f(x) = \frac{1}{2\pi} \sum_{h=-\infty}^{\infty} e^{-ihx} R(h) \geq 0 \quad \forall x \in [-\pi; \pi]$  esetén.

**Definíció. Pozitív szemidefinit függvény.** A  $g : \mathbb{Z} \rightarrow \mathbb{C}$  függvény pozitív szemidefinit, ha minden  $n \in \mathbb{Z}_+$  és minden  $t_1, \dots, t_n \in \mathbb{Z}$  esetén a  $[g(|t_i - t_j|)]_{i,j=1,\dots,n}$  mátrix pozitív szemidefinit.



**Tétel. Az autokovariancia függvény spektrális reprezentációja.**

Az  $R(h)$  függvény egy gyengén stacionárius folyamat autokovariancia függvénye  $\iff \exists F : [-\pi; \pi] \rightarrow \mathbb{R}$  jobbról folytonos, nem-csökkenő, korlátos,  $F(-\pi) = 0$  függvény, amire  $R(h) = \int_{-\pi}^{\pi} e^{ihx} dF(x)$ .

A fenti tételben lévő  $F$  neve: **spektrális eloszlásfüggvény**. Ha

- $\exists f : F(x) = \int_{-\pi}^x f(y) dy$ , akkor azt mondjuk, hogy a folyamat *folytonos spektrumú*  $f$  spektrális sűrűségfüggvénnyel;
- $F$  tiszta ugrófüggvény, akkor azt mondjuk, hogy a folyamat *diszkrét spektrumú*.

*Következmény.*  $F(\pi) = R(0) = D^2 X_t$ , így  $F$  nem eloszlásfüggvény (valószínűségszámítási értelemben), mert előfordulhat, hogy  $F(\pi) \neq 1$ !

A következőkben két általánosabb eredményt mondunk ki.

**Tétel. Herglotz-tétel.** Legyen  $R : \mathbb{Z} \rightarrow \mathbb{C}$  pozitív szemidefinit függvény. Ekkor létezik olyan  $Q$  véges mérték  $[-\pi; \pi]$  intervallumon, amire  $R(h) = \int_{[-\pi; \pi]} e^{ihx} dQ(x)$ .

Idősorelméletben a Herglotz-tételt az  $R$ -rel jelölt autokovariancia függvényre használjuk, amiről könnyen látható, hogy pozitív szemidefinit. A Herglotz-tételben szereplő  $Q$  mértéket **spektrálmérték**nek nevezzük. Ebből a spektrális eloszlásfüggvény:  $F(x) = Q([-\pi, x])$ , illetve amennyiben  $Q$  abszolút folytonos a  $\lambda$  Lebesgue-mértékre nézve, akkor az  $f = \frac{dQ}{d\lambda}$  Radon-Nikodym derivált a spektrális sűrűségfüggvény.

*Megjegyzés.* Ebben a tételben egy mérték szerinti integrál szerepel, míg az egyvel korábbi tételben Riemann-Stieltjes értelemben vett integrál volt.

Egy kis kitekintés: nemcsak a sztochasztikus folyamat autokovariancia függvényének, hanem magának a folyamatnak is van spektrális előállítása, ezt mutatja be a következő tétel.

**Tétel. Sztochasztikus folyamat spektrális reprezentációja.**

Legyen  $T = \mathbb{Z}$ ,  $X_k$  0 várható értékű gyengén stacionárius folyamat. Ekkor létezik olyan  $\phi$  ortogonális sztochasztikus mérték, amelyre  $X_k = \int_{[-\pi; \pi]} e^{ik\mu} d\phi(\mu)$ ,  $k \in \mathbb{Z}$ .

Ebben a tételben két dolog is a levegőben lóg:

- mi az a sztochasztikus mérték (a lényege röviden: halmazhoz valószínűségi változót rendel), illetve mikor lesz ortogonális;
- hogyan definiálandó egy ilyen mérték szerinti integrál.