

Sztochasztikus idősormodellek

Ferenci Tamás
tamas.ferenci@medstat.hu

Tartalom

Tartalomjegyzék

1. Matematikai emlékeztető	1
1.1. Valószínűségszámítás emlékeztető	1
1.2. Algebra emlékeztető	2
2. A sztochasztikus idősorelemzési iskola	2
3. ARMA-modellek	6
3.1. WN-folyamat	6
3.2. MA-modellek	6
3.3. AR-modellek	8
3.4. ARMA-modellek	10
4. Az ARMA-folyamatok mélyebb matematikája	10
4.1. A késleltetési operátor és a késleltetési polinom	10
4.2. ARMA-folyamatok reprezentációja késleltetési polinomokkal	12

1. Matematikai emlékeztető

1.1. Valószínűségszámítás emlékeztető

Várható érték

Ki fogjuk használni a következőket:

- A várható érték lineáris: $\mathbb{E}(\sum_i X_i) = \sum_i \mathbb{E}X_i$
- A várható érték lineáris: $\mathbb{E}(cX) = c\mathbb{E}X$
- Konstans várható értéke saját maga: $\mathbb{E}c = c$

Szórásnégyzet

Ki fogjuk használni a következőket:

- A szórásnégyzet nem lineáris: $\mathbb{D}^2(\sum_i X_i) = \sum_i \mathbb{D}^2 X_i$ ha X_i -k (páronként) korrelálatlanok (szemben a várható értékkel, ez *nem* mindig igaz!); ne feledjük, a függetlenség implikálja a korrelálatlanságot

- A szórásnégyzet nem lineáris: $\mathbb{D}^2(cX) = c^2\mathbb{D}^2X$
- Konstans szórásnégyzete nulla: $\mathbb{D}^2c = 0$

Kovariancia és korreláció

Ki fogjuk használni a következőket:

- A kovariancia/korreláció bilineáris: $\text{cov}\left(\sum_i X_i, \sum_j Y_j\right) = \sum_i \sum_j \text{cov}(X_i, Y_j)$
- A kovariancia/korreláció bilineáris: $\text{cov}(aX, bY) = ab \text{cov}(X, Y)$
- Konstans mindennel korrelálatlan: $\text{cov}(c, X) = 0$
- Az önkovariancia a variancia: $\text{cov}(X, X) = \mathbb{D}^2X$

1.2. Algebra emlékeztető

Változó, hatvány, polinom, polinom gyöke és inverze

- Legyen x egy változó, x^k egy hatványa, ekkor $\omega_0 + \omega_1x + \omega_2x^2 + \dots + \omega_kx^k = \omega(x)$ egy k -ad fokú, egyváltozós – polinom, $\omega_0, \omega_1, \omega_2, \dots, \omega_k$ együtthatókkal
- (Az együtthatók és a változó értéke legegyszerűbb esetben valós számok, de ez nem szükségszerű)
- Megengedjük, hogy a fokszám végtelen is lehessen: $\omega(x) = \sum_{i=0}^{\infty} \omega_i x^i$
- Polinom inverze: $\omega^{-1}(x)$ olyan, hogy $\omega^{-1}(x)\omega(x) = 1$
- Polinom gyöke: az $\omega(x) = 0$ egyenlet megoldása
- Az algebra alaptétele: egy k -ad fokú valós polinomnak k darab – nem feltétlenül különböző – gyöke van, melyek vagy valósak, vagy ha komplexek, akkor konjugált párokban jönnek
- Az előbbi miatt egy polinom mindig felírható úgy – gyöktényezős alak – mint $\omega(x) = \left(1 - \frac{1}{r_1}x\right) \left(1 - \frac{1}{r_2}x\right) \dots \left(1 - \frac{1}{r_k}x\right)$, ahol r_i az i -edik gyök

Polinom invertálása

- Például $1 - ax$ inverze $1 + ax + (ax)^2 + (ax)^3 + \dots$ (egyesével egyeztetve az együtthatókat)
- Ez egy hatványsor, konvergál, ha $|ax| < 1$
- Általános esethez induljunk ki a gyöktényezős alakból:

$$\begin{aligned} \omega^{-1}(x) &= \left[\left(1 - \frac{1}{r_1}x\right) \left(1 - \frac{1}{r_2}x\right) \dots \left(1 - \frac{1}{r_k}x\right) \right]^{-1} = \\ &= \left(1 - \frac{1}{r_1}x\right)^{-1} \left(1 - \frac{1}{r_2}x\right)^{-1} \dots \left(1 - \frac{1}{r_k}x\right)^{-1} = \\ &= \prod_{i=1}^k \left[1 + \frac{1}{r_i}x + \left(\frac{1}{r_i}x\right)^2 + \left(\frac{1}{r_i}x\right)^3 + \dots \right] \end{aligned}$$

- Ami konvergál, ha minden i -re $\left| \frac{1}{r_i} x \right| < 1$
 - Ha $|x| = 1$, akkor a feltétel, hogy $|r_i| > 1$, azaz, hogy mindegyik gyök 1-nél nagyobb abszolútértékű legyen, más szóval, hogy a komplex egységkörön kívül legyen (ugye a gyökök komplexek is lehetnek)

2. A sztochasztikus idősoelemzési iskola

Filozófiai alapok

- Determinisztikus (például dekompozíciós idősormodellek) vs. sztochasztikus idősoelemzés
- A determinisztikus iskolában is van – természetesen – véletlen, csak a szerepe más: pusztán arra korlátozódik, hogy az *adott időszak* értéket beállítsa
- A sztochasztikus iskolában ezzel szemben a véletlen az *egész későbbi* lefutást befolyásolja, a véletlennek „folyamatépítő szerepe” van
- Lássunk egy példát, hogy jobban megértsük mit jelentenek ezek a kissé homályos megfogalmazások!

Példa a két iskolára

- Az egyik idősorunk – sokasági modellel megadva – legyen

$$Y_t^{(D)} = \alpha t + u_t,$$

ahol α konstans, $u_t \sim \mathcal{N}(0, \sigma^2)$ függetlenül

- A másik modell legyen

$$Y_t^{(S)} = Y_{t-1}^{(S)} + \alpha + u_t,$$

ahol α és u_t mint előbb, $Y_0^{(S)}$ pedig legyen 0

- A további elemzésekhez hasznos lesz a következő átalakítás:

$$\begin{aligned} Y_t^{(S)} &= Y_{t-1}^{(S)} + \alpha + u_t = \left(Y_{t-2}^{(S)} + \alpha + u_{t-1} \right) + \alpha + u_t = \\ &= \left[\left(Y_{t-3}^{(S)} + \alpha + u_{t-2} \right) + \alpha + u_{t-1} \right] + \alpha + u_t = \dots = \\ &= \alpha t + \sum_{i=1}^t u_i \end{aligned}$$

- Hasonlítanak is, meg nem is...

Hasonlóság

Számítsuk ki a μ_t várható érték függvényeket:

$$\mu_t^{(D)} = \mathbb{E}(\alpha t + u_t) = \mathbb{E}(\alpha t) + \mathbb{E}(u_t) = \alpha t + 0 = \alpha t$$

$$\mu_t^{(S)} = \mathbb{E} \left(\alpha t + \sum_{i=1}^t u_i \right) = \alpha t + \sum_{i=1}^t 0 = \alpha t$$

Különbség


Nézzük most meg a σ_t^2 szórásnégyzet függvényeket:

$$\begin{aligned}\sigma_t^{2(D)} &= \mathbb{D}^2(\alpha t + u_t) = \mathbb{D}^2(\alpha t) + \mathbb{D}^2(u_t) = 0 + \sigma^2 = \sigma^2 \\ \sigma_t^{2(S)} &= \mathbb{D}^2\left(\alpha t + \sum_{i=1}^t u_i\right) = \mathbb{D}^2(\alpha t) + \mathbb{D}^2\left(\sum_{i=1}^t u_i\right) = 0 + \sum_{i=1}^t \sigma^2 = \\ &= t\sigma^2\end{aligned}$$


Az igazi eltérés a viselkedésben

- Ennek sokkal mélyebb magyarázatát kapjuk, ha arra gondolunk, hogy a viselkedésük miben más
- Segítség: kidobunk egy nagyon deviáns u_t -t (pl $\sigma^2 = 1$ mellett +5-öt vagy -5-öt), miben tér el a két idősor későbbi viselkedése?
- Ez a két extrém véglet:
 - Az $Y_t^{(D)}$ -nél már a *rögtön következő* időpontban sincsen *semmilyen* hatása ennek
 - $Y_t^{(S)}$ -nél viszont az idősor *egész későbbi lefutását* befolyásolja, *csorbítatlanul*
- Bizonyos értelemben *ugyanazt* a trendet jelentik – gondoljunk a várható érték függvényre – de mégis teljesen eltérő *viselkedéssel*
- Megtestesítik a két iskolát: $Y_t^{(D)}$ a lineáris trend a determinisztikus szemléletben (véletlen szerepe: csak az adott időszakra korlátozódik), az $Y_t^{(S)}$ a lineáris trend sztochasztikus értelemben (véletlen szerepe: folyamatépítő)


Hogy néznek ki?



Hogy néznek ki?



Hogy néznek ki?



Más elnevezések

- Főleg sztochasztikus folyamatok kontextusban az $Y_t^{(S)}$ -et $\alpha = 0$ esetén **véletlen bolyongásnak** (random walk, RW) is szokás nevezni
- Ráragok egy bábút az origóra a számegeyenesen, dobok egy véletlen számot (u_t) és annyival odébb rakom, majd ezt ismétlem \rightarrow bolyongani fog a számegeyenesen
- (Folytonos határa a Wiener-folyamat)
- Az $\alpha \neq 0$ esetben pedig **eltolásos véletlen bolyongásról** (random walk with drift, RWD) szoktak beszélni
- Amennyiben az RW-t log-skálán vesszük, tehát $\log Y_t = \log Y_{t-1} + u'_t$ a modellünk, $Y_0 \neq 0$ mellett (eredeti skálára visszavetítve: $Y_t = Y_{t-1} \cdot u_t = Y_0 \cdot \prod_{i=1}^t u_i$; nem a növekmények, hanem a hányadosok adott fae változók, nagyobb értékeknél nagyobb ingadozás) akkor **geometriai véletlen bolyongásról** szokás beszélni (pénzügyes szóhasználatban!)

3. ARMA-modellek

3.1. WN-folyamat

A fehérzaj (WN) folyamat

- A folyamat

$$u_t,$$

melyre $\mathbb{E}(u_t) = 0$, $\mathbb{D}^2(u_t) = \sigma^2$ és $\text{cov}(u_t, u_s) = 0$ ($t \neq s$)

- Jele: $\mathcal{WN}(0, \sigma_u^2)$
- Az eloszlásról nem mondtunk semmit
- Néha feltesszük, hogy nem csak korrelálatlan, de független is (általában nem ez az alapértelmezés, külön kell mondani); egyedül normális eloszlás feltevése esetén mindegy
- Zaj: logikus, ez valamilyen teljesen modellezhetetlen, struktúra nélküli folyamat
- De mitől fehér? ... optikai analógia!

A fény is felfogható egy idősornak, hiszen egy elektromágneses rezgés. Itt a spektrális elemzés nagyon jól érthető tartalommal bír, hiszen a fény frekvenciája egész egyszerűen a színe! (Ilyen értelemben a prizma, mely a ráejtett fényt „szétbontja” összetevő színeire, igazából nem más, mint egy spektrális elemzés fizikai implementációja!) Ismert, hogy a fehér fény az, amely azonosan tartalmaz minden színt; a fenti értelemben tehát a fehér fény spektruma egy vízszintes egyenes. A két dolog ott kapcsolódik össze, hogy belátható, hogy a fenti definiált idősor spektruma szintén egy vízszintes egyenes lesz – ilyen értelemben tehát a színek közül a fehér idősoros megfelelője.

3.2. MA-modellek

A mozgóátlagú (MA) modell

A q -ad rendű mozgóátlagú modell (modell, mivel most a sokaságban specifikáljuk):

$$Y_t = \alpha + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q},$$

ahol u_t hiba(folyamat), szokták itt úgy is hívni, hogy innováció, fehérzaj-folyamatnak tételezzük fel: $u_t \sim \mathcal{WN}(0, \sigma_u^2)$; α és θ_i -k valós, σ_u^2 pozitív valós konstans paraméterek

MA(1)-folyamat: várhatóérték-függvény

Közvetlenül a definíció alapján (a várhatóérték-képzést „ráeresztve” a definícióra):

$$\mu_t = \alpha + 0 + \theta_1 \cdot 0 = \alpha,$$

tehát μ_t időfüggetlen

MA(1)-folyamat: szórásnégyzet-függvény

Közvetlenül a definíció alapján (a szórásnégyzet-képzést „ráeresztve” a definícióra):

$$\sigma_t^2 = 0 + \sigma_u^2 + \theta_1^2 \sigma_u^2 = \sigma_u^2 (1 + \theta_1^2)$$

tehát σ_t^2 időfüggetlen (ez lesz γ_0)

MA(1)-folyamat: autokovariancia-függvény

Közvetlenül a definíció alapján (a kovariancia-képzést „ráeresztve” a definícióra):

$$\text{cov}(Y_t, Y_{t-1}) = \text{cov}(\alpha + u_t + \theta_1 u_{t-1}, \alpha + u_{t-1} + \theta_1 u_{t-2}) = \dots$$

összesen 9 tag, ebből azonban csak 1 nem-nulla (a többiben vagy konstans van, vagy különböző időpontokhoz tartozó u -k érintkeznek):

$$\dots = \text{cov}(\theta_1 u_{t-1}, u_{t-1}) = \theta_1 \sigma_u^2,$$

tehát ez időfüggetlen, jogos a γ_1 jelölés

MA(1)-folyamat: autokovariancia-függvény

Közvetlenül a definíció alapján (a kovariancia-képzést „ráeresztve” a definícióra):

$$\text{cov}(Y_t, Y_{t-k}) = \text{cov}(\alpha + u_t + \theta_1 u_{t-1}, \alpha + u_{t-k} + \theta_1 u_{t-k-1}),$$

amiben immár – az előbbi logikát követve – mindegyik tag nulla ha $k > 1$.

Összefoglalva:

$$\gamma_k = \begin{cases} \sigma_u^2 (1 + \theta_1^2) & \text{ha } k=0 \\ \theta_1 \sigma_u^2 & \text{ha } k=1 \\ 0 & \text{ha } k>1 \end{cases}$$

MA(1)-folyamat: stacionaritás

Az előbbieket összerakva (μ_t időfüggetlen, σ_t^2 időfüggetlen, γ_k csak késleltetéstől függ) tehát kapjuk, hogy az MA(1) folyamat stacioner.

Mégpedig *mindig* az (értsd: paraméter-választástól függetlenül).

MA(1)-folyamat: korrelogram

- ACF: $\rho_k = \frac{\gamma_k}{\gamma_0}$; eltűnik 1 késleltetés után
- PACF: belátható, hogy lecsengő (azaz $\lim_{k \rightarrow \infty} \text{PACF}(k) = 0$)

MA(q)-folyamatok

- $\mu_t = \alpha$ (ugyanazért)
- $\sigma_t^2 = \sigma_u^2 (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)$ (ugyanazért)
- ACF k késleltetés után eltűnő (ugyanazért)
- PACF lecsengő (ugyanúgy kiszámolható lenne)
- Mindig stacioner (paraméter-választástól függetlenül)!

3.3. AR-modellek

Az autoregresszív (AR) modell

A p -ed rendű autoregresszív modell (modell, mivel most a sokaságban specifikáljuk):

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + u_t,$$

ahol u_t hiba(folyamat), szokták itt úgy is hívni, hogy innováció, fehérzaj-folyamatnak tételezzük fel: $u_t \sim \mathcal{WN}(0, \sigma_u^2)$; α és ϕ_i -k valós, σ_u^2 pozitív valós konstans paraméterek

Megjegyzések

- Speciális esetek: ha $p = 1$ és $\phi_1 = 1$, akkor RWD (ha ráadásul $\alpha = 0$ akkor RW)
- Stacionaritás: ez – szemben az MA-folyamatokkal – nyilván nem lehet *mindig* stacioner, hiszen az RW sem az, de *néha* lehet az is (pl. $p = 1$ és $\phi_1 = 0$), a stacionaritásnak tehát itt valamilyen – paraméterekre vonatkozó – feltétele kell legyen
- Ennek vizsgálatát későbbre halasztjuk, és most azt mondjuk, hogy teljesültek ezek a feltételek

AR(1) folyamat: várhatóérték-függvény

Vegyük mindkét oldal várhatóértékét (feltettük a stacionaritást, $\mathbb{E}(Y_t) \equiv \mu$)

$$\mu = \alpha + \phi_1 \mu + 0,$$

mivel a várhatóérték lineáris, innen

$$\mu = \frac{\alpha}{1 - \phi_1}$$

($\phi_1 \neq 1$ kell legyen: látni fogjuk, hogy ez tényleg fennáll, ha stacioner)

AR(1) folyamat: szórásnégyzet-függvény

Vegyük mindkét oldal szórásnégyzetét (feltettük a stacionaritást, $\mathbb{D}^2(Y_t) \equiv \sigma^2$)

$$\sigma^2 = \phi_1^2 \sigma^2 + \sigma_u^2,$$

kihasználva, hogy a három tag korrelálatlan, innen

$$\sigma^2 = \frac{\sigma_u^2}{1 - \phi_1^2}$$

($|\phi_1| < 1$ kell legyen: látni fogjuk, hogy ez tényleg fennáll, ha stacioner)

AR(1) folyamat: autokovariancia-függvény

Kezdjük az 1 késleltetéssel (természetesen a stacionaritást most is feltételezzük):

$$\begin{aligned} \text{cov}(Y_t, Y_{t-1}) &= \text{cov}(\alpha + \phi_1 Y_{t-1} + u_t, Y_{t-1}) = \\ &= 0 + \phi_1 \text{cov}(Y_{t-1}, Y_{t-1}) + 0 = \phi_1 \sigma^2 = \phi_1 \frac{\sigma_u^2}{1 - \phi_1^2}, \end{aligned}$$

időfüggetlen; innen rekurzívan mehetünk tovább:

$$\text{cov}(Y_t, Y_{t-k}) = \text{cov}(\alpha + \phi_1 Y_{t-1} + u_t, Y_{t-k}) = \phi_1 \gamma_{k-1},$$

szintén időfüggetlen, ezekből tehát indukcióval kapjuk, hogy

$$\gamma_k = \phi_1^k \sigma^2 = \frac{\phi_1^k \sigma_u^2}{1 - \phi_1^2}$$

($|\phi_1| < 1$ kell legyen: látni fogjuk, hogy ez tényleg fennáll, ha stacioner)

AR(1) folyamat: autokorreláció és parciális autokorreláció-függvény

Definíció alapján az autokovariancia-függvényből (mivel stacioner):

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \phi_1^k,$$

tehát az ACF *geometriailag lecsengő*

Külön kellene igazolni, de a mechanika alapján is elég nyilvánvaló, hogy

$$\text{PACF}(k) = \begin{cases} \rho_1 & \text{ha } k=1 \\ 0 & \text{ha } k>1 \end{cases}$$

Épp az MA(1) „fordítva”: a kettő korrelogramja egymás *duálisa*

AR(1) folyamatok RWD-nél látott rekurzív visszafejtése

$$\begin{aligned} Y_t &= \alpha + \phi_1 Y_{t-1} + u_t = \alpha + \phi_1 (\alpha + \phi_1 Y_{t-2} + u_{t-1}) + u_t = \\ &= \alpha + \phi_1 \alpha + \phi_1^2 (\alpha + \phi_1 Y_{t-3} + u_{t-2}) + \phi_1 u_{t-1} + u_t = \dots \end{aligned}$$

Ha feltételezzük, hogy „végtelenből jön” a folyamat (ekkor a kezdőérték mindegy lesz), akkor ez

$$\dots = \alpha \sum_{i=0}^{\infty} \phi_1^i + \sum_{i=0}^{\infty} \phi_1^i u_{t-i} = \frac{\alpha}{1 - \phi_1} + \sum_{i=0}^{\infty} \phi_1^i u_{t-i}$$

($|\phi_1| < 1$ kell legyen: látni fogjuk, hogy ez tényleg fennáll, ha stacioner)

Mint egy MA-modell: ez az $AR(1)$ modell $MA(\infty)$ -reprezentációja

AR(p) folyamatok

- Stacionaritást egyelőre itt is feltételezzük
- Várhatóérték-függvény: $\mu = \frac{\alpha}{1 - \phi_1 - \phi_1 - \dots - \phi_p}$
- Szórásnégyzet-függvény $\gamma_0 = \frac{\sigma_u^2}{1 - \phi_1^2 - \phi_2^2 - \dots - \phi_p^2}$
- Az ACF lecsengő (végtelenben 0-ba tart), de már bonyolultabb mintázat szerint is lehet
- PACF-ből az első p nem-nulla, a többi viszont már nulla
- Tehát az azonos rendű AR és MA folyamatok korrelogramja általánosságban is egymás duálisa
- Van $MA(\infty)$ -reprezentációja

3.4. ARMA-modellek

Az autoregresszív-mozgóátlagú (ARMA) modell

A p, q rendű autoregresszív-mozgóátlagú modell (modell, mivel most a sokaságban specifikáljuk):

$$\begin{aligned} Y_t &= \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \\ &+ u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}, \end{aligned}$$

ahol u_t hiba(folyamat), szokták itt úgy is hívni, hogy innováció, fehérzaj-folyamatnak tételezzük fel: $u_t \sim \mathcal{WN}(0, \sigma_u^2)$; α, ϕ_i -k és θ_i -k valós, σ_u^2 pozitív valós konstans paraméterek.

Tulajdonságok

- Stacionaritásnak feltétele van (ami csak az AR együtthatóktól függ)
- Ha fennáll, akkor mind az ACF, mind a PACF lecsengő (nem eltűnő), lehet, hogy bonyolultabb mintázat szerint
- Van $MA(\infty)$ -reprezentációja

4. Az ARMA-folyamatok mélyebb matematikája

4.1. A késleltetési operátor és a késleltetési polinom

A késleltetési operátor

- Legyen L valami, ami idősről egy másik idősort csinál (ha y az eredeti idősor, akkor Ly jelöli az újat)
- ... mégpedig úgy, hogy $(Ly)_t = y_{t-1}$
- Az egyszerűség kedvéért most fókuszáljunk a minta (realizálódott) idősorra, ne a sokasági szemléletre
- Fogjuk fel úgy, mint egy függvényt, ami az időkhöz értékeket rendel: $y : \{1, 2, \dots, T\} \rightarrow \mathbb{R}$ és $y : t \mapsto y_t$
- Az L tehát függvényből egy másik függvényt csinál: *operátor*

A késleltetési operátor (precízebben)

- A „függvény” itt igazából egy vektor ($\mathbf{y} = (y_1 \ y_2 \ \dots \ y_T)^T$)
- (Ez rendben is van: egy n dimenziós valós vektor felfogható egy $\{1, 2, \dots, n\} \rightarrow \mathbb{R}$ függvényként!)
- Ezek a függvények egy vektorteret alkotnak (függvény: a vektortér eleme, skalárral szorzás: pontonként szorzás, összeadás: pontonkénti összeadás), ezt szokás függvénytérnek nevezni
- A fenti esetben ez megfelel az n -dimenziós valós vektorokkal végzett szokásos műveleteknek
- Az operátor – úgy általában – igazából két vektortér közti leképezés
- A függvényteres értelmezés miatt mondhattuk azt, hogy az „operátor az, ami függvényből másik függvényt csinál”!

A késleltetési operátor (precízebben)

- Ha a vektoros felfogást, és azon belül is az n -dimenziós valós vektoroknak való megfeleltetést vesszük, akkor minden operátor reprezentálható mátrixszal (hiszen a mátrix az, ami vektorból vektort csinál!)
- Ez alól a késleltetési operátor sem kivétel, például:

$$\underbrace{\begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}}_{\mathbf{L}} \cdot \underbrace{\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{pmatrix}}_{\mathbf{y}} = \begin{pmatrix} 0 \\ y_2 \\ y_3 \\ y_4 \end{pmatrix},$$

- (Azért, hogy ne változzon az idősor hossza, az új első eleme legyen fixen 0)

A késleltetési operátor hatványai

- Micsoda L^2 ?
- Könnyen értelmezhető: $L(Ly_t) = Ly_{t-1} = y_{t-2}$
- Röviden: $L^2y_t = y_{t-2}$
- Megfeleltethető a mátrixoknak? Igen! Az \mathbf{L} mátrix négyzete épp a kettővel késleltetést valósítja meg, azaz $\mathbf{L}^2 = L^2$
- Szorozzuk össze, és ellenőrizzük le, hogy ez csakugyan teljesül!
- Hasonlóan $L^k y_t = y_{t-k}$, tehát ez a k -val késleltető operátor lesz
- (Ideértve azt is, hogy például $L^{-1}y_t = y_{t+1}$, „siettető operátor”)

A késleltetési polinom

- A késleltetett idősorokat kombinálhatjuk is, például $2y_t + 3y_{t-1} - 4y_{t-2} = 2y_t + 3Ly_t - 4L^2y_t = \dots$
- Most jön az érdekes rész: ez átírható mint

$$\dots = (2 + 3L - 4L^2) y_t$$

- Ami fontos, hogy ez nem „szintaktikai manipuláció”, az előbbi mátrixok nagyon is mutatják ennek a realitását: $2\mathbf{I} + 3\mathbf{L} - 4\mathbf{L}^2$ épp az a mátrix, amivel rászorozva az idősorra *pont* $2y_t + 3y_{t-1} - 4y_{t-2}$ -t kapjuk!
- Ennek általánosítása a késleltetési polinom:

$$\omega(L) = \omega_0 + \omega_1 L + \omega_2 L^2 + \dots + \omega_k L^k,$$

azaz az operátorokból is ugyanúgy gyárthatunk polinomot – az előbb definiált hatványaik segítségével – mint mondjuk valós ismeretlenekből

- Ezzel $\omega(L) y_t = \omega_0 y_t + \omega_1 y_{t-1} + \omega_2 y_{t-2} + \dots + \omega_k y_{t-k}$
- Természetesen $\omega(L)$ maga is egy operátor

A késleltetési polinom használatának előnye

Számos – egyébként bonyolult – művelet elvégezhető, mint (jól ismert) manipuláció polinomokkal: összeszorozhatóak, invertálhatóak stb.!

4.2. ARMA-folyamatok reprezentációja késleltetési polinomokkal

ARMA-folyamatok felírása késleltetési polinomokkal

- Emlékeztetőül:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

- Kicsit átrendezve:

$$Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p} = \alpha + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

ARMA-folyamatok felírása késleltetési polinomokkal

- Az előbbieket alapján ez átírható mint

$$\begin{aligned} Y_t - \phi_1 L Y_t - \phi_2 L^2 Y_t - \dots - \phi_p L^p Y_t &= \\ &= \alpha + u_t + \theta_1 L u_t + \theta_2 L^2 u_t + \dots + \theta_q L^q u_t \end{aligned}$$

- Azaz:

$$\begin{aligned} (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) Y_t &= \\ &= \alpha + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) u_t \end{aligned}$$

- Vezessünk be két késleltetési polinomot: $\phi(x) = 1 - \phi_1 x - \phi_2 x^2 - \dots - \phi_p x^p$ és $\theta(x) = 1 + \theta_1 x + \theta_2 x^2 + \dots + \theta_q x^q$
- Ezekkel az előbbi egész egyszerűen

$$\phi(L) Y_t = \alpha + \theta(L) u_t$$

ARMA-folyamatok vizsgálata polinomiális reprezentációval: stacionaritás

- Az előbbi egyenletet átalakítva:

$$Y_t = \phi^{-1}(L) \alpha + \phi^{-1}(L) \theta(L) u_t$$

- Legalábbis, ha $\phi(L)$ invertálható!
- Ehhez az kell, hogy a gyökei a polinomnak az egységkörön kívül legyenek
 - Mert az L úgy viselkedik, mint az 1 abszolútértékű szám (1 az operátornormája)
- Lényegében azt jelenti, hogy létezik $MA(\infty)$ -reprezentáció
- És most jön a lényeg: ez épp a *stacionaritás* feltétele!
- (Persze ez bizonyítást igényel)

ARMA-folyamatok vizsgálata polinomiális reprezentációval: invertálhatóság

- Ha viszont $\theta(L)$ gyökei vannak az egységkörön kívül, akkor az egész $AR(\infty)$ -folyamatként reprezentálható
- Ilyenkor azt mondjuk, hogy a folyamat *invertálható*
- Lényegében azt jelenti, hogy az u_t is felírható Y aktuális és múltbeli értékeivel (nem csak fordítva)