

Statsionaarsed aegread

Teemad

- Viitajad ja aegride diferentsimine
- Juhuslikud protsessid ja nende karakteristikud
- Range ja nõrk statsionaarsus
- Autokorrelatsioon ja selle testimine
- ARIMA mudelid
- Box-Jenkinsi meetodika
- Prognoosimine ja prognooside hindamine

Aegride analüüs.

- Ei ole seletavaid tunnuseid, st ei uurita muutuste põhjuseid.
 - analüüs põhineb majandusprotsesside inertsusel
- Ühemõõtmeline modelleerimine (*univariate modelling*): meil on ainult ühe tunnuse muutus ajas.
 - VAR mudelite korral ka mitmemõõtmeline modelleerimine
- Eesmärgid:
 - Lühiajaline prognoosimine (ARIMA mudelid, veaparandusmudelid ECM)
 - Statsionaarsuse määramine, trendi kindlakstegemine (ühikjuure testid)
 - Pikaajaliste seoste leidmine (kointegratsioon)

Põhilised teisendused

- Viitaegade leidmine
- Diferentsimine
 - 1. ja kõrgemat järku diferentsid
 - sesoonsed diferentsid
- Logaritmine (naturaallogaritm)
- Diferentsid logaritmist
- Eesmärgiks on trendi ja sesoonsuse eemaldamine

Viitaeg ja diferentsid

- Aegrea y_t esimest järku viitajaks (*lag*) nimetatakse aegrida y_{t-1}
- k -ndat järku viitaeg on aegrida y_{t-k}
- Aegrea esimest järku diferents on aegrea järjestikuste liikmete vahe

$$\Delta y_t = y_t - y_{t-1}$$

- Aegrea teist järku diferents on aegrea järjestikuste esimest järku diferentside vahe

$$\Delta^2 y_t = \Delta y_t - \Delta y_{t-1} = y_t - 2y_{t-1} + y_{t-2}$$

- k -ndat järku diferents on järjestikuste $k-1$ järku diferentside vahe

$$\Delta^k y_t = \Delta^{k-1} y_t - \Delta^{k-1} y_{t-1}$$


- **Sesoonseks diferentsiks** nimetatakse aegrea aastast muutu.

$$\text{Kvartaalsete andmete korral} \quad \Delta_4 y_t = y_t - y_{t-4}$$

$$\text{Kuiuste andmete korral} \quad \Delta_{12} y_t = y_t - y_{t-12}$$

Näide: keskmine brutopalk Eestis


Aasta, kvartal	Brutopalk, kr	1. järku diferents	Sesoonne diferents 1. järku diferentsidest
2004: 1	6748		
2004: 2	7417	669=7417-6748	
2004: 3	7021	-396=7021-7417	
2004: 4	7704	683	
2005: 1	7427	-277	
2005: 2	8291	864	195=864-669
2005: 3	7786	-505	-1369
...



JUHUSLIKUD PROTSESSID JA STATIONAARSUS

Stohhastiline ehk juhuslik protsess

Juhuslik suurus Y võib erinevatel ajamomentidel omada erineva tõenäosusega erinevaid väärtusi.




- Võimalikud olekud (väärtused) konkreetsel ajamomendil. Punkti suurus näitab oleku tõenäosust.

Võimalike olekute järjestus annab trajektoori ehk juhusliku protsessi mingi kindla **realisatsiooni**

Stohhastiline - juhuslik, tõenäone
Kreeka k. *stokhos* sihtmärk, *stokhastikos* õigesti oletatav


Juhusliku protsessi erinevad realisatsioonid



Läbilõikeandmed	Aegrad
Kogum	Genereeriv protsess
Valim	Realisatsioon


Uurida saame vaid juhusliku protsessi üht konkreetselt realiseeritud realiseerimist. Selle põhjal peame tegema järeldusi genereeriva protsessi kohta.

Näide: USA SKP 1970-1991




1975. a I kv väärtus võib olla suvaline arv, mis sõltub paljudest valitsevatest majanduslikest ja poliitilistest tingimustest. 3154,1 mlrd USD on nende kõikvõimalike väärtuste üks konkreetne realiseerimine.

Olulisemad juhuslikud protsessid



Valge müra (*white noise*) u_t
 $Cov(u_t, u_{t-i}) = 0$

Igal ajahetkel "starditakse" ühest ja samast kohast. "Ei mäleta", kuhu jõudis eelmisel ajahetkel. Mäluta protsess.




Juhuslik ekslemine (*random walk*)

$$y_t = y_{t-1} + u_t$$

Igal järgmisel ajahetkel "starditakse" sealt, kuhu jõuti eelmisel ajahetkel. "Mäletatakse" eelmist positsiooni. Mäluga protsess.

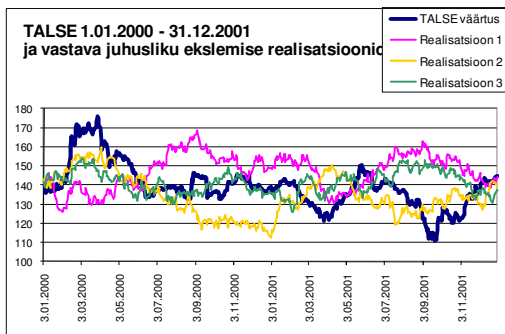
Näide: valge müra aktsiaturgudel

Arco Vara aktsia keskmine tulumäär päevas (%) 20.06.2013-21.08.2013 ja juhusliku protsessi poolt genereeritud aegrida.



Aritmeetiline keskmine -0,07%, standardhälve 1,96%

Näide: juhuslik ekslemine aktsiaturgudel



Juhusliku protsessi karakteristikud

keskväärtus $E[y_t] = \mu_t$
 dispersioon $Var(y_t) = E[(y_t - \mu)^2] = \sigma^2(y_t)$
 autokovariatsioon $Cov(y_t, y_{t-i}) = E[(y_t - \mu)(y_{t-i} - \mu)] = \gamma(y_t, y_{t-i})$

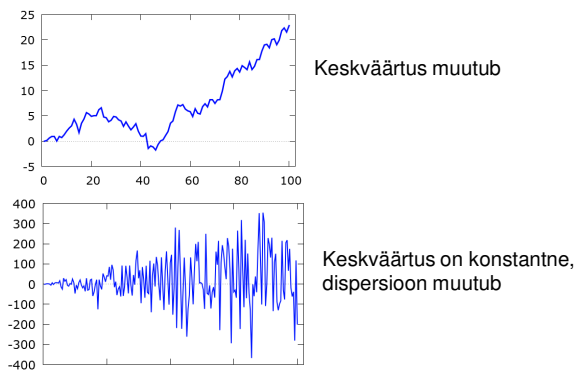
Keskvärtus iseloomustab keskmist taset.
Dispersioon iseloomustab hajumist.
Kovariatsioon iseloomustab juhusliku suuruse erinevate väärtuste vahelist statistilist seost.

Autokovariatsioon: aegre korral on erinevateks väärtusteks erinevatele ajaperioodidele (või momentidele) vastavad väärtused y_t ja y_{t-i}

Kui $Cov(y_t, y_{t-i}) = 0$ siis y_t ja y_{t-i} sõltumatud.


Demo: karakteristikud

Karakteristikud üldiselt muutuvad ajas



Mittestatsionaarne protsess

Üldiselt on igal ajamomendil erinev tõenäosusjaotus



Ansambli ja aegre keskvärtus

Realisatsioon 1	$x_1(t_1), x_2(t_2), \dots, x_1(T)$	Ansambli keskvärtus on üle erinevate realisatsioonide. Ei ole vaadeldav
Realisatsioon m	$x_m(t_1), x_m(t_2), \dots, x_m(T)$	
Realisatsioon M	$x_M(t_1), x_M(t_2), \dots, x_M(T)$	

$$E[X(t_i)] = \frac{1}{M} \sum_{m=1}^M x_m(t_i)$$

Realisatsioon 1	$x_1(t_1), x_2(t_2), \dots, x_1(T)$	Aegre keskvärtus on vaadeldav
Realisatsioon m	$x_m(t_1), x_m(t_2), \dots, x_m(T)$	
Realisatsioon M	$x_M(t_1), x_M(t_2), \dots, x_M(T)$	

$$\bar{x} = \frac{1}{T} \sum_{t=1}^T x_m(t)$$

Range statsionaarsus.

Juhuslik protsess on rangelt statsionaarne (*strongly stationary*), kui vastava juhusliku suuruse tõenäosusjaotus ajas ei muutu.

Ka statsionaarsus kitsamas mõttes.

- Modelleerimiseks ja prognoosimiseks on vajalik statsionaarsus.
- Rangelt statsionaarsust on praktikas võimatu kontrollida

Nõrk statsionaarsus

Juhuslik protsess on **nõrgalt statsionaarne** (*weakly stationary*), kui tema tõenäosuslikud omadused ei muutu ajas (on ajas invariantid):

konstantne keskvärtus $E(y_t) = E(y_{t+m}) = \mu < \infty$,
 konstantne dispersioon $\sigma^2(y_t) = \sigma^2(y_{t+m}) = \sigma^2 < \infty$,
 konstantne autokovariatsioon $\gamma(y_t, y_{t-j}) = \gamma(y_{t+m}, y_{t+m-j}) = \gamma_j$
 Kovariatsioon sõltub vaid ajamomentide vahest j

Ka

- statsionaarsus laiemas mõttes (*stationarity in wide sense*)
- kovariantne statsionaarsus (*covariance stationarity*)


Edaspidi mõeldakse statsionaarsuse all nõrka statsionaarsust

Valge müra

Valge müra korral igale ajahetkele t vastavad juhuslikud suurused u_t on

1. **üksteisest sõltumatud**: $Cov(u_t, u_{t-j}) = 0$ iga t ja $j \neq 0$ korral
2. konstantse keskvärtusega $E(u_t) = \mu$;
3. konstantse dispersiooniga: $Var(u_t) = \sigma^2$

Valge müra on **statsionaarne** protsess. Aga statsionaarseid protsesse on teisigi.



Valge müra tähtsaim omadus: autokovariatsiooni puudumine ehk sõltumatus.


See eristab seda teistest protsessidest.

AUTOKORRELATSIOON JA SELLE TESTIMINE


Autokorrelatsioon

Üheks oluliseks aegrea omaduseks on perioodil t esineva aegrea väärtuse sõltuvus varasemate perioodide väärtustest.

Seda sõltuvust nimetatakse **autokorrelatsiooniks**.



Autokorrelatsioon puudub



Kuidas hinnata autokorrelatsiooni tugevust või selle puudumist? **Vaja kvantitatiivset näitajat!**

Autokorrelatsioonikordaja

Autokorrelatsiooni mõõdab **autokorrelatsioonikordaja** (AC)

Kui meil on antud aegrida y_t , $t=1, 2, \dots, n$, siis saame moodustada $n-1$ arvupaari (y_1, y_2) , (y_2, y_3) , ..., (y_{t-1}, y_t) .

Autokorrelatsioonikordaja näitajate y_t ja y_{t-1} vahel:





y_1	y_2
y_2	y_3
...	...
y_{t-1}	y_t

Märkus: See on ligikaudne valem, kehtib pikkade aegride korral ($n > 50$)

$$\rho_1 = \frac{\sum_{t=2}^n (y_{t-1} - \bar{y})(y_t - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad \text{kus keskvärtus} \quad \bar{y} = \frac{1}{n} \sum_{t=1}^n y_t$$


$$-1 \leq \rho \leq 1$$

Millal on autokorrelatsioon positiivne




Korrelatsioonidiagrammid, y_{t-1} ja y_t

- Autokorrelatsioonikordaja on **positiivne**, kui
- kasvamisele järgneb kasvamine
 - kahanemisele järgneb kahanemine



Millal on autokorrelatsioon negatiivne




Korrelatsioonidiagramm, y_{t-1} ja y_t

Autokorrelatsioonikordaja on **negatiivne**, kui

- kasvamisele järgneb kahanemine
- kahanemisele järgneb kasvamine

Millal autokorrelatsioon puudub



Korrelatsioonidiagramm, y_{t-1} ja y_t


Autokorrelatsioon **puudub** kui

- kasvamisele järgneb
 - mõnikord kahanemine
 - mõnikord kasvamine
- kahanemisele järgneb
 - mõnikord kahanemine
 - mõnikord kasvamine

Kui väike peaks olema autokorrelatsioonikordaja absoluutväärtus, et võiksime öelda: "autokorrelatsioon puudub"?
Vaja **kriteeriumi!**

Autokorrelatsioon ja kõrgemat järku viitajad

Ajamomendile t vastav aegrea väärtus y_t võib sõltuda mitte ainult eelmisele ajamomendile $t-1$ vastavast väärtusest y_{t-1} , vaid ka varasematest väärtustest $y_{t-2}, y_{t-3}, \dots, y_{t-k}$.



Vastavalt

1. järku autokorrelatsioon
2. järku autokorrelatsioon
3. järku autokorrelatsioon
-
- k -ndat järku autokorrelatsioon

Autokorrelatsioonifunktsioon ACF

1. järku autokorrelatsioonikordaja mõõdab vahetult järgnevate vaatluste vahelist korrelatsiooni

$$\rho_1 = \frac{\sum_{t=2}^n (y_{t-1} - \bar{y})(y_t - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2}$$

k -ndat järku autokorrelatsioonikordaja mõõdab vaatluste y_{t-k} ja y_t vahelist korrelatsiooni

$$\rho_k = \frac{\sum_{t=k+1}^n (y_{t-k} - \bar{y})(y_t - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2}$$

$$\rho_1, \rho_2, \rho_3, \dots, \rho_k \rightarrow \rho(k)$$

Autokorrelatsioonifunktsioon (ACF) on autokorrelatsioonikordaja sõltuvus viitajast k .

Näide: keskmise palga autokorrelatsiooni funktsioon

Aasta, kvartal	y_t	y_{t-1}	y_{t-2}	y_{t-3}	y_{t-4}
2004, 1	6748				
2004, 2	7417	6748			
2004, 3	7021	7417	6748		
2004, 4	7704	7021	7417	6748	
2005, 1	7427	7704	7021	7417	6748
2005, 2	8291	7427	7704	7021	7417
2005, 3	7786	8291	7427	7704	7021
2005, 4	8690	7786	8291	7427	7704
2006, 1	8591	8690	7786	8291	7427
2006, 2	9531	8591	8690	7786	8291
2006, 3	9068	9531	8591	8690	7786
2006, 4	10212	9068	9531	8591	8690

Autokorrelatsioonikordajad

- 1. järku 0,524
- 2. järku 0,566
- 3. järku 0,144
- 4. järku 0,144

Autokorrelatsiooni statistilise olulisuse testimine

- **Nullhüpotees:** kõik autokorrelatsioonikordajad kuni viitajani k on nullid,
 - st autokorrelatsioon puudub;
 - st genereerivaks protsessiks on valge müra.
- **Sisukas hüpotees:** esineb autokorrelatsioon
- Testimiseks kasutatavad statistikud
 - Q statistik (ka Portmanteau statistik, Box-Pierce statistik)
 - Box-Ljungi statistik. Sobivam väikeste valimite korral.
- Mõlemad alluvad suurte valimite korral χ^2 jaotusele. Vabadusastmete arv = viitajate arv.
- Kui statistiku väärtus on suurem, kui χ^2 kriitiline väärtus (olulisuse tõenäosus on väiksem kui valitud olulisuse nivoo), võtta vastu sisukas hüpotees, autokorrelatsioon esineb.

Box-Ljung'i statistik

$$Q_{BL} = n(n+2) \sum_{j=1}^k \frac{\rho_j^2}{n-j} \sim \chi^2(k)$$


Autorid Box ja Ljung (1978)

n – aegrea pikkus, st aegrea väärtuste arv
 k – mitmenda viitajani autokorrelatsiooni uuritakse
 ρ_j – j -järku autokorrelatsioonikordaja

- Mitmenda viitajani ehk kui suur võtta k väärtus?
- Ühest kriteeriumi ei ole.
- Leitakse statistiku väärtused **erinevate** viitaegade arvu k korral. Vaadatakse näiteks, millal autokorrelatsioon muutub statistiliselt mitteoluliseks.


Osaline autokorrelatsioon PACF

- Uurime näiteks, kuidas jaanuarikuu väärtus mõjutab aprillikuu väärtust. St viitaeg on 3.
- Selleks leiame vastava autokorrelatsioonikordaja ρ_3 .
- Aga: jaanuarikuu väärtus mõjutab ka veebruarikuu väärtust, see omakorda märtsikuu oma, mis omakorda aprilli väärtust.
- ρ_3 väärtust mõjutavad ka vahepealsed mõjud, need tuleks elimineerida
- Statistikas on olemas mõiste "osakorrelatsioonikordaja", mis mõõdab suuruste x ja y vahelise seose tugevust tingimusel, et näitajate z_1, z_2, \dots, z_m mõju on eemaldatud.



Osaline autokorrelatsioon mõõdab autokorrelatsiooni y_{t-k} ja y_t vahel, kusjuures vahepealsete väärtuste mõju on elimineeritud.

Näide: valge müra autokorrelatsioonifunktsioon ja Box-Ljung'i statistik



$$Q_{BL} = n(n+2) \sum_{j=1}^k \frac{\rho_j^2}{n-j}$$

Variable->Correlogram

LAG	ACF	PACF	Q-stat.	[p-value]
1	-0,0481	-0,0481	0,1227	[0,726]
2	0,0977	0,0956	0,6397	[0,726]
3	0,0049	0,0139	0,6411	[0,867]
4	0,1504	0,1436	1,9204	[0,750]
5	0,1139	0,1296	2,6703	[0,751]
6	-0,0995	-0,1182	3,2552	[0,776]
7	0,0188	-0,0185	3,2765	[0,858]
8	-0,0614	-0,0702	3,5100	[0,898]
9	-0,1330	-0,1870	4,6309	[0,865]
10	0,0432	0,0624	4,7521	[0,907]


olulisuse tõenäosus

Autokorrelatsioonifunktsioon

Osalise autokorrelatsioonifunktsioon

H_0 : autokorrelatsioon puudub. Aegrida on genereeritud valge müra poolt.

Näide: juhusliku ekslemise autokorrelatsioonifunktsioon ja Box-Ljung'i statistik

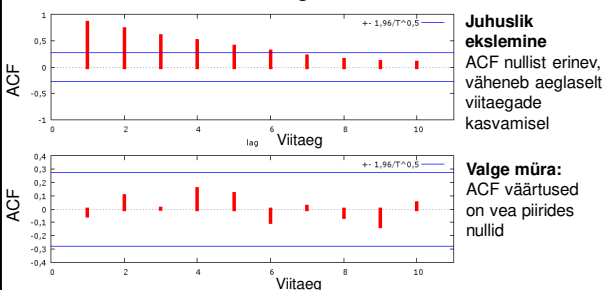


LAG	ACF	PACF	Q-stat.	[p-value]
1	0,8420 ***	0,8420 ***	37,6144	[0,000]
2	0,7249 ***	0,0551	66,0808	[0,000]
3	0,5933 ***	-0,1028	85,5528	[0,000]
4	0,4951 ***	0,0244	99,4051	[0,000]
5	0,3990 ***	-0,0348	108,6034	[0,000]
6	0,3026 **	-0,0743	114,0138	[0,000]
7	0,2034	-0,0777	116,5151	[0,000]
8	0,1448	0,0630	117,8136	[0,000]
9	0,1017	0,0234	118,4701	[0,000]
10	0,0855	0,0449	118,9455	[0,000]

olulisuse tõenäosus

H_1 : esineb autokorrelatsioon

Korrelogrammid



- Korrelogrammil esitatakse autokorrelatsioonifunktsioon visuaalselt
- Võimaldab esile tuua tunnuse ajalise käitumise iseloomu, mida on raske kindlaks teha aegrea enda vaatlemisel.

ARIMA MUDELID

ARMA modelleerimise eesmärk

Aegrea autokorrelatsiooni struktuur püütakse esitada ARIMA mudeli abil.

See, mis ARIMA mudelist üle jääb, on valge müra.

Põhiliseks kasutusvaldkonnaks on **lühiajaline prognoosimine**:

- makroökonomika aegread
- finantsaegread
- ettevõtluses nõudlus

Võetud üle elektrinseneride poolt kasutatud signaalide filtreerimisest, mis töötati välja 1930-ndatel. Laiemalt võeti kasutusele pärast G.E.P.Box ja G. Jenkins'i raamatu Time Series Analysis: Forecasting and Control ilmumist 1971. a.

Libiseva keskmise mudelid MA

Valge müra üldistus: juhuslike liikmete ehk šokkide u_t kaalutud libisev keskmine (*moving average*, MA)

$$y_t = \mu + u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q} \quad u_{t-i} \text{ on valge müra}$$

$$MA(q) \quad y_t = \mu + u_t + \sum_{i=1}^q \theta_i u_{t-i}$$

"Mäletab" eelmisi šokke u_{t-i}

$$y_t = \mu + u_t + \theta_1 u_{t-1} \quad MA(1), 1. \text{ järku libisev keskmine}$$


$$y_t = \mu + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} \quad MA(2), 2. \text{ järku libisev keskmine}$$

MA liikmete interpretatsioon I

MA kordajad iseloomustavad juhuslike šokkide mõju järgnevatele aegrea liikmetele.


$$y_t = \mu + u_t + 0,1u_{t-1}$$

Eelmise šoki u_{t-1} mõju on väiksem



$$y_t = \mu + u_t + 0,8u_{t-1}$$


Eelmise šoki u_{t-1} mõju on suurem




MA liikmete interpretatsioon, II

$$y_t = \mu + u_t + 0,8u_{t-1} + 0,5u_{t-2}$$


Mõju avaldavad nii eelmise šokk u_{t-1} kui ka üle-eelmise šokk u_{t-2}



Näide: libiseva keskmise mudelid MA



$$y_t = 1 + u_t + 0,6u_{t-1}$$



$$y_t = 1 + u_t + 0,6u_{t-1} + 0,3u_{t-2}$$

MA(q) protsessi karakteristikud

$$y_t = \mu + u_t + \sum_{i=1}^q \theta_i u_{t-i}$$

Keskväärus $E(y_t) = \mu$

Konstantne

Dispersioon $\sigma^2(y_t) = \sigma^2(u_t) \left(1 + \sum_{i=1}^q \theta_i^2 \right)$ $\sigma^2(u_t)$ konstantne, järelikut $\sigma^2(y_t)$ konstantne

Kovariatsioon $\text{cov}(y_t, y_{t-k}) = \begin{cases} \sigma^2 \left(1 + \sum_{i=k+1}^q \theta_i \theta_{i-k} \right), & k \leq q \\ 0, & k > q \end{cases}$ Konstantne

MA(q) protsess on statsioonaarne

Autoregressiivsed mudelid AR

Autoregressiivne mudel: aegrea liikmed sõltuvad eelnevatest liikmetest (viitaegadest)

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + u_t$$

$$\text{AR}(p) \quad y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + u_t \quad u_t \text{ on valge müra}$$

"Mäletab" eelmisi väärtusi y_{t-i}


$$y_t = c + \phi_1 y_{t-1} + u_t \quad 1. \text{ järku autoregressiivne mudel AR}(1)$$

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + u_t$$


2. järku autoregressiivne mudel AR(2)

AR liikmete interpretatsioon


- Autoregressiivsus tähendab, et esineb nõ "taastav jõud", mis sunnib aegrida pöörduma tagasi keskvärtuse poole (*mean reversion*).
- Keskvärtusele lähenemise kiiruse määrab AR kordajate summa. Kui kordajate summa on
 - väike, toimub tagasipöördumine kiiresti;
 - suur, toimub tagasipöördumine aeglasemalt.



Näited: autoregressiivsed mudelid



$$y_t = 1 + 0,6y_{t-1} + u_t$$



$$y_t = 1 + 0,6y_{t-1} + 0,3y_{t-2} + u_t$$

AR(p) protsessi keskvärtus

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + u_t$$

$$\text{Keskvärtus} \quad E(y_t) = \frac{c}{1 - \sum_{i=1}^p \phi_i} = \mu$$

Kui nimetaja $1 - \sum_{i=1}^p \phi_i = 0$, siis keskvärtus pole defineeritud

Sellisel juhul ühikjuure protsess, mittestatsionaarne

Millal on AR protsess statsionaarne?


AR(p) protsessi statsionaarsuse tingimus

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + u_t$$

$$\text{Karakteristlik võrrand} \quad 1 - \phi_1 \lambda - \phi_2 \lambda^2 - \dots - \phi_p \lambda^p = 0$$

Karakteristliku võrrandi juured (lahendid) $\lambda_1, \lambda_2, \dots, \lambda_p$ (üldiselt kompleksed)

AR(p) protsess on statsionaarne, kui kõik karakteristlikud juured asuvad väljaspool ühikringi.



Ühikring kompleksstasandil

Vt õpik Brooks lk 217 näide 5.3

AR(1) protsessi statsionaarsuse tingimus

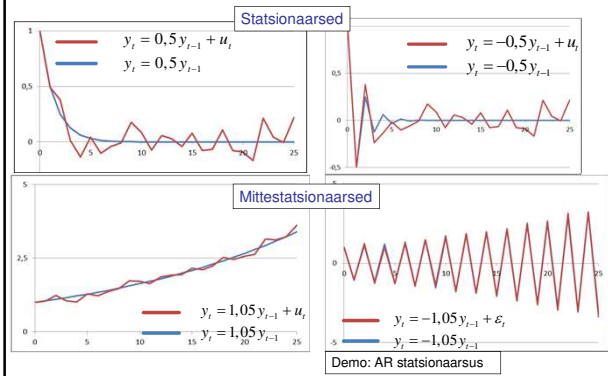
$$\text{AR}(1) \quad y_t = c + \phi_1 y_{t-1} + u_t$$

$$\text{Karakteristlik võrrand} \quad 1 - \phi_1 \lambda = 0 \quad \text{Lahend} \quad \lambda = \frac{1}{\phi_1}$$

$$\text{Tingimus} \quad |\lambda| > 1 \Rightarrow \frac{1}{|\phi_1|} > 1 \quad \text{Väljaspool ühikringi}$$

AR(1) protsess on statsionaarne, kui $|\phi_1| < 1$

Näited: statsionaarsed ja mittestatsionaarsed AR(1) protsessid



Autoregressiivsed libiseva keskmise mudelid

$$\text{AR}(1) \quad y_t = c + \phi_1 y_{t-1} + u_t \quad \text{MA}(1) \quad y_t = c + u_t + \theta_1 u_{t-1}$$

$$\text{ARMA}(1,1) \quad y_t = c + \phi_1 y_{t-1} + u_t + \theta_1 u_{t-1}$$

Esimest järku autoregressiivne libiseva keskmise mudel

Demo: ARMA(1,1)

(p,q) järku autoregressiivne libiseva keskmise mudel

$$\text{ARMA}(p,q) \quad y_t = c + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q}$$

p järku autoregressiivne komponent
q järku libiseva keskmise komponent

Olulisemad ARMA (p,q) mudelid

Mudel	Tähistus	Valem
Valge müra	ARMA(0,0)	$y_t = c + u_t$
1. järku autoregressiivne AR(1)	ARMA(1,0)	$y_t = c + \phi_1 y_{t-1} + u_t$
2. järku autoregressiivne AR(2)	ARMA(2,0)	$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + u_t$
1. järku libisev keskmine MA(1)	ARMA(0,1)	$y_t = c + u_t + \theta_1 u_{t-1}$
2. järku libisev keskmine MA(2)	ARMA(0,2)	$y_t = c + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2}$
1. järku autoregressiivne libisev keskmine	ARMA(1,1)	$y_t = c + \phi_1 y_{t-1} + u_t + \theta_1 u_{t-1}$

Integreeritud protsess

- Protsess on **1-st järku integreeritud**, kui protsess on mittestatsionaarne, aga selle 1. järku diferentside aegrida on statsionaarne.
 - Tähistus I(1)
- Protsess on **k-ndat järku integreeritud** (integrated of order k), kui protsessi k-ndat järku diferents on statsionaarne protsess.
 - st statsionaarsuse saavutamiseks tuleb k korda diferentsida
 - tähistus I(k)
- Kui protsess on statsionaarne, st statsionaarsuse saavutamiseks pole vaja diferentsida, on I(0) protsess

Integreeritud AR mudelid

Kui aegrea 1. järku diferentsid on kirjeldatavad AR(1) mudeli abil

$$\Delta y_t = c + \phi_1 \Delta y_{t-1} + u_t$$

siis aegrida ise on genereeritud autoregressiivse protsessi ARI (1,1) poolt ja on esitatav järgmiselt

$$y_t = c + (1 + \phi_1) y_{t-1} - \phi_1 y_{t-2} + u_t \quad \text{ARI}(1,1)$$

Kui aegrea statsionaarsuse saavutamiseks tuleb seda diferentsida 2 korda, esitab aegrida mudel ARI(1,2)

Üldiselt ARI (p,d)

Integreeritud MA mudelid

Kui aegrea 1. järku diferentsid on kirjeldatavad MA(1) mudeli abil

$$\Delta y_t = c + u_t + \theta_1 u_{t-1}$$

siis aegrida ise on genereeritud autoregressiivse protsessi IMA (1,1) poolt ja on esitatav järgmiselt

$$y_t = c + y_{t-1} + u_t + \theta_1 u_{t-1} \quad \text{IMA}(1,1)$$

Kui aegrea statsionaarsuse saavutamiseks tuleb seda diferentsida 2 korda, esitab aegrida mudel IMA(2,1)

Üldiselt IMA(d,q)

ARIMA: Integreeritud ARMA mudelid

Autoregressiivsed integreeritud libiseva keskmise mudelid
 $ARIMA(p,d,q)$

- p autoregressiivse osa järk
- d diferentside järk
- q libiseva keskmise järk

- Kui aegrida vajab diferentsimist, siis diferentsitakse seda (tavaliselt 1 või 2 korda) ja diferentsidele rakendatakse sobivat $ARMA(p,q)$ mudelit.
- d järku diferentside $ARMA(p,q)$ mudel on ekvivalentne $ARIMA(p,d,q)$ mudeliga

Näited

$ARIMA(1,1,0)$ 1. järku diferentside aegrida on $AR(1)$ tüüpi
 $ARIMA(0,2,2)$ 2. järku diferentside aegrida on $MA(2)$ tüüpi

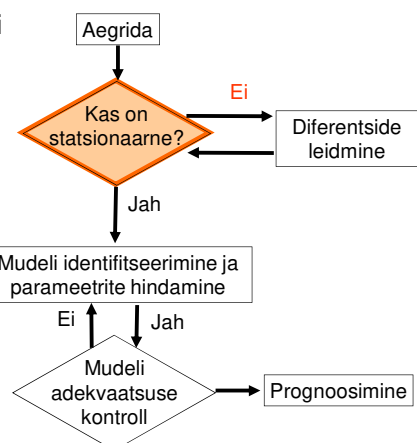
BOX - JENKINSI METOODIKA

Box - Jenkinsi meetodika

Box ja Jenkins (1970) pakkusid välja ARMA mudelite jaoks süstemaatilise lähenemise:

- Mudeli identifitseerimine, st ARMA järkude (p,q) kindlaks määramine
 - korrelogrammide abil
 - informatsioonikriteeriumi abil
- Mudeli parameetrite hindamine
- Mudeli adekvaatsuse hindamine (diagnostika)
 - kas parameetrid on statistiliselt olulised
 - kas jäägid moodustavad valge müra (jääkide autokorrelatsiooni testimine)

Box-Jenkinsi meetodika

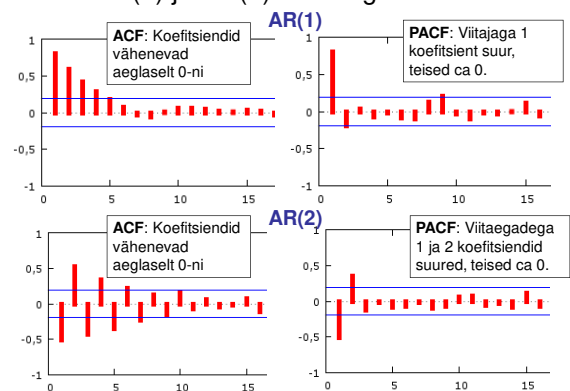


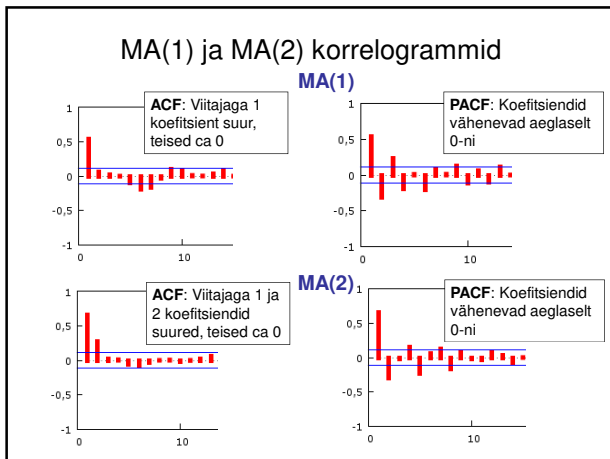
Mudeli identifitseerimine

- Otsustatakse
 - Kas on vaja aegrida diferentsida ja kui, siis mitu korda
 - Mitmendat järku autoregressiivset (AR) ja libiseva keskmise (MA) operaatorit kasutada.
 - Tavaliselt üks valik 5-st võimalusest: $AR(1)$, $AR(2)$, $MA(1)$, $MA(2)$, $ARMA(1,1)$
- AR ja MA valikul võib tugineda
 - Aegrea autokorrelatsiooni (ACF) ning osalise autokorrelatsiooni funktsioonile (PACF) ja vastavate korrelogrammide visuaalsele uurimisele
 - Informatsioonikriteeriumitele: valitakse mudel, mille korral vastav näitaja on väikseim

Demo: korrelogrammid

AR(1) ja AR(2) korrelogrammid





ARMA mudeli valik korrelogrammide põhjal

Mudel	ACF	PACF
AR(1), $\beta_1 > 0$	Eksponentsiaalne vähenemine 0-ni	Viitajaga 1 koefitsient suur, teised ca 0
AR(1), $\beta_1 < 0$	Ostsilleeruv vähenemine 0-ni	Viitajaga 1 koefitsient suur
AR(p)	Eksponentsiaalne või ostsilleeruv vähenemine 0-ni	Viitajani p koefitsiendid nullist erinevad.
MA(1), $\theta_1 > 0$	Viitajaga 1 koefitsient suur, teised ca 0	Ostsilleeruv vähenemine 0-ni
MA(1), $\theta_1 < 0$	Viitajaga 1 koefitsient suur	Eksponentsiaalne vähenemine 0-ni
MA(2)	Viitajaga 1 ja 2 koefitsiendid suured, teised ca 0	Eksponentsiaalne või ostsilleeruv vähenemine 0-ni
ARMA(1,1)	Eksponentsiaalne või ostsilleeruv vähenemine 0-ni	Eksponentsiaalne või ostsilleeruv vähenemine 0-ni

Kokkuvõte: AR ja MA järkude määramine ACF ja PACF järgi

Autoregressiivne protsess AR

- eksponentsiaalselt või ostsilleeruvalt kahanev ACF
- oluliselt nullist erinevad PACF väärtused annavad AR järgud

Libiseva keskmise protsess MA

- eksponentsiaalselt või ostsilleeruvalt kahanev PACF
- oluliselt nullist erinevad ACF väärtused annavad MA järgud

PROBLEEM: tihti pole ACF ja PACF graafikute järgi võimalik mudelit üheselt identifitseerida. Siis abiks **informatsioonikriteeriumid**.

Informatsioonikriteeriumid

Akaike informatsioonikriteerium $AIC = \ln(\hat{\sigma}^2) + \frac{2k}{T}$ Akaike Information Criteria

Jääkliikmete dispersioon $\hat{\sigma}^2 = \frac{SSE}{T}$ kus SSE jääkliikmete ruutude summa

k - hinnatavate parameetrite arv, ARMA(p,q) mudeli korral $k=p+q+1$, T valimi maht (aegrea pikkus)

$\ln(\hat{\sigma}^2)$ vähenemist kompenseerib k/T suurenemine. Kui 2. liidetava $2k/T$ suurenemine ületab $\ln(\hat{\sigma}^2)$ vähenemisest saadava efekti, siis AIC summaarselt suureneb. Siis ei ole mudelisse uue liikme lisamine õigustatud.

Paremaks loetakse mudelit, mille korral AIC on väiksem.

Schwarzi kriteerium SIC (ka BIC ehk Bayesi informatsioonikriteerium)

$BIC(k) = \ln(\hat{\sigma}^2) + \frac{k}{T} \ln T$ Uute liikmete lisamise suhtes "kriitilisem", kui AIC, sest teine liidetav suureneb kiiremini

Näide valik AIC ja BIC põhjal

AIC					
p/q	0	1	2	3	4
0	610,7	607	585,3	585,5	586,2
1	601,7	588,5	583,6	579,6	581,5
2	581,4	583,3	585	581,5	583,5
3	583,2	585	586,8	580,1	580,6
4	584,9	587	580,6	579,9	580,9

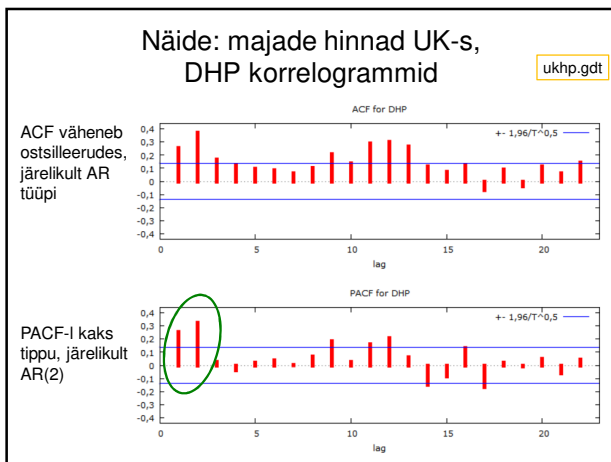


ARIMA(4,3)

BIC					
p/q	0	1	2	3	4
0	614	616,8	598,5	601,9	605,7
1	611,6	601,6	600	599,3	604,5
2	594,5	600	604,6	604,5	609,7
3	600	604,7	609,8	606,3	610,1
4	604,6	609,9	606,8	609,4	580,9

ARIMA(4,4)

ARMA mudeli parameetrite hindamine

- Pärast mudeli identifitseerimist viiakse läbi mudeli parameetrite hindamine
- Mudeli diagnostika
 - Kas parameetrite hinnangud on statistiliselt olulised?
 - Kas mudeli jääkliikmed (*residuals*) moodustavad valge müra?
 - leitakse jääkliikmete ACF ja PACF ning uuritakse vastavaid korrelogramme
 - valge müra test Box-Jungi statistiku Q põhjal
 - Kas jääkliikmed alluvad normaaljaotusele?
- Eesmärgiks on ARMA mudelisse koondada aegrea autokorrelatsiooni struktuur, et **järele jääks ainult valge müra**



Näide: majade hinnad UK-s, AR(2) mudeli aruanne

	coefficient	std. error	z	p-value
const	0,635701	0,147303	4,316	1,59e-05 ***
phi_1	0,168334	0,0671496	2,507	0,0122 **
phi_2	0,329653	0,0676692	4,872	1,11e-06 ***

	Real	Imaginary	Modulus	Frequency
AR Root 1	1,5050	0,0000	1,5050	0,0000
AR Root 2	-2,0156	0,0000	2,0156	0,5000

Näide: majade hinnad UK-s, AR(2) mudeli aruanne

	coefficient	std. error	z	p-value
const	0,635701	0,147303	4,316	1,59e-05 ***
phi_1	0,168334	0,0671496	2,507	0,0122 **
phi_2	0,329653	0,0676692	4,872	1,11e-06 ***

	Mean dependent var	S.D. dependent var	Mean of innovations	S.D. of innovations	Log-likelihood	Akaike criterion	Schwarz criterion
	0,636252	1,146288	0,002366	1,043960	-286,6917	581,3834	594,4959

Näide: majade hinnad UK-s, AR(2) mudeli kirjutamine

AR(2) mudeli üldkuju $y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + u_t$

AR(p) keskvaartuse valemist $\mu = \frac{c}{1 - \sum_{i=1}^p \phi_i} \Rightarrow c = \mu \left(1 - \sum_{i=1}^p \phi_i \right)$

Arvutame c $c = 0,635701 \cdot (1 - 0,168334 - 0,329653) \approx 0,319$

NB! See on keskvaartus μ

$$y_t = 0,319 + 0,168y_{t-1} + 0,330y_{t-2} + u_t$$

	coefficient	std. error	z	p-value
const	0,635701	0,147303	4,316	1,59e-05 ***
phi_1	0,168334	0,0671496	2,507	0,0122 **
phi_2	0,329653	0,0676692	4,872	1,11e-06 ***

Näide: majade hinnad UK-s, jääkliikmete autokorrelatsiooni testimine

LAG	ACF	PACF	Q-stat.	[p-value]
1	0,0544	0,0544	0,5897	[0,443]
2	0,0204	0,0175	0,6726	[0,714]
3	0,0422	0,0403	1,0300	[0,794]
4	-0,0523	-0,0875	2,3998	[0,663]
5	0,0886	0,0976	3,9945	[0,550]
6	0,0044	-0,0057	3,9985	[0,677]
7	-0,0507	-0,0473	4,5268	[0,717]
8	0,0498	0,0416	5,0394	[0,753]
9	0,1089	0,1240 *	7,5002	[0,585]
10	-0,0152	-0,0378	7,5486	[0,673]
11	0,1311 *	0,1223 *	11,1533	[0,431]
12	-0,0743	-0,0861	12,3179	[0,421]
13	0,1252 *	0,1568 **	15,6436	[0,269]
14	-0,0498	-0,1215 *	16,1713	[0,303]
15	0,0022	0,0673	16,1724	[0,371]
16	0,0938	0,0424	18,0699	[0,320]
17	-0,1238 *	-0,1032	21,3917	[0,209]
18	0,0593	0,0393	22,1571	[0,225]
19	-0,0398	-0,0490	22,5042	[0,260]
20	0,0388	0,0606	22,8369	[0,297]
21	-0,0204	-0,0696	22,9290	[0,348]
22	0,0046	0,0055	22,9338	[0,405]
23	0,0078	0,0447	22,9475	[0,464]
24	0,1273 *	0,0805	26,6026	[0,323]
25	0,0784	0,0883	27,9967	[0,308]
26	0,0370	0,0185	28,3097	[0,343]

Valge müra kuni viitajani 26

PROGNOOSIMINE

Prognoosimine ja tinglik keskvärtus

Aegrida $Y_t = \{y_1, y_2, \dots, y_T\}$

Eeldame, et genereeriv protsess on hinnatud, st

1. korrelatsiooni struktuur on teada;
2. parameetrid on hinnatud.

Tähistame kogu informatsiooni, mis on teada ajahetkeks t Ω_t

Seda informatsiooni kasutades saame leida aegrea tinglikku keskvärtuse ajahetkel $t+1$

$$E[y_{t+1} | \Omega_t]$$

Ajahetkel t tehtud prognoos (*forecast*) F on tinglik keskvärtus, sõltub ajahetkeks t teadaolevast informatsioonist.

$$F_{t,1} = E[y_{t+1} | \Omega_t] \quad 1 \text{ samm edasi}$$

$$F_{t,h} = E[y_{t+h} | \Omega_t] \quad h \text{ sammu edasi}$$

Prognoosimine MA mudeli korral

MA(3) mudel $y_t = \mu + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \theta_3 u_{t-3}$

Erineva pikkusega prognoosid ajahetkel t .

$$F_{t,1} = E[y_{t+1} | \Omega_t] = \mu + \theta_1 u_t + \theta_2 u_{t-1} + \theta_3 u_{t-2}$$

$$F_{t,2} = E[y_{t+2} | \Omega_t] = \mu + \theta_2 u_t + \theta_3 u_{t-1}$$

$$F_{t,3} = E[y_{t+3} | \Omega_t] = \mu + \theta_3 u_t$$

$$F_{t,4} = E[y_{t+4} | \Omega_t] = \mu$$

$$F_{t,5} = E[y_{t+5} | \Omega_t] = \mu$$

.....

Kui prognoosime kaugemale, kui MA protsessi järk q , on prognoosiks protsessi keskvärtus:

$$F_{t,h} = E[y_{t+h} | \Omega_t] = \mu, \quad h > q$$

MA protsessi mälu pikkus on q perioodi. See määrab ära prognoosi horisondi.

Prognoosimine AR mudeli korral

Näiteks AR(2) mudel $y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + u_t$

Erineva pikkusega prognoosid ajahetkel t .

$$F_{t,1} = E[y_{t+1} | \Omega_t] = c + \phi_1 y_t + \phi_2 y_{t-1}$$

$$F_{t,2} = E[y_{t+2} | \Omega_t] = c + \phi_1 F_{t,1} + \phi_2 y_t$$

$$F_{t,3} = E[y_{t+3} | \Omega_t] = c + \phi_1 F_{t,2} + \phi_2 F_{t,1}$$

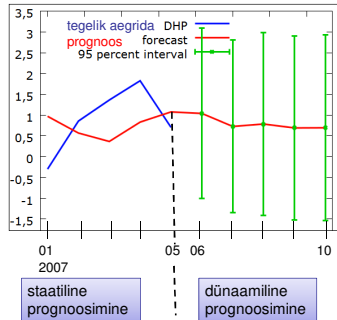
Prognoosimisel kasutatakse eelmisi prognoose

Staatiline ja dünaamiline prognoosimine

- Dünaamiline prognoosimine
 - Aluseks olemasolevad tegelikud väärtused + eelnevalt prognoositud väärtused
 - Prognoositakse väärtusi, mis pole teada (praktiline vajadus)
- Staatiline prognoosimine
 - Ühesammuline prognoosimine
 - Järgmise väärtuse prognoosimiseks võetakse aluseks eelmised aktuaalsed väärtused.
 - Võimalik ainult valimi sees (*in sample*)
 - Kasutatakse mudeli prognoosimisvõime hindamiseks

Näide: staatiline ja dünaamiline prognoosimine


Majade hinnad UK-s, hinna muutus protsentides. Aegrida kuni 05.2007. Prognoos kuni 10.2007



Prognoosi punkthinnang ja vahemikhinnang

$$F_{t,h} = E[y_{t+h} | \Omega_t] \text{ punkthinnang}$$

Vahemikhinnang: antakse prognoosi usalduspiirid 95%-lise usaldatavusega.



Prognooside hindamine prognoosivea järgi

- $ME = \frac{1}{T} \sum_{t=1}^T u_t$ Mean Error, keskmine viga
 Iseloomustab prognoosi nihet: üles või alla
- $MSE = \frac{1}{T} \sum_{t=1}^T u_t^2$ Mean Square Error, ruutkeskmine viga
- $RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T u_t^2}$ Root Mean Square Error, juuritud ruutkeskmine viga
- $MAE = \frac{1}{T} \sum_{t=1}^T |u_t|$ Mean Absolute Error, keskmine absoluutne viga
- $MPE = 100 \frac{1}{T} \sum_{t=1}^T \frac{u_t}{y_t}$ Mean Percentage Error, keskmine suhteline viga, protsentides
- $MAPE = 100 \frac{1}{T} \sum_{t=1}^T \frac{|u_t|}{|y_t|}$ Mean Absolute Percentage Error, keskmine absoluutne suhteline viga, protsentides

Näide: Eesti THI 1998-2012

Modelleeriti 1. järku diferentse.

- AR(1) AR(2)
- Mõlema mudeli korral jääkliikmetel autokorrelatsioon puudub 12. viitajani
 - Jääkliikmed ei allu normaaljaotusele.

Akaike ik	347,86	345,53 *
Schwarzi ik	357,42 *	358,28

Mean Error	-0,00099305	-0,0017645
Mean Squared Error	0,39523	0,38573
Root Mean Squared Error	0,62868	0,62107
Mean Absolute Error	0,48171	0,47873
Mean Percentage Error	-0,0077465	-0,0067933
Mean Absolute Percentage Error	0,3307	0,3288
Theil's U	0,76658	0,76079

Prognoos mõnevõrra parem

Theil'i U (programmis Gretl)

Naiivne prognoos: $y_{t+1} = y_t$

Mingi mudeli abil saadud prognoos F_t

Kui palju on mudeli abil tehtud prognoos parem naiivsest prognoosist?

$$U = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^{T-1} \left(\frac{F_{t+1} - y_{t+1}}{y_t} \right)^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^{T-1} \left(\frac{y_t - y_{t+1}}{y_t} \right)^2}}$$

mudeli abil tehtud prognoosi põhjal

naiivse prognoosi põhjal

- $U > 1$ mudeli abil tehtud prognoos on halvem, kui naiivne prognoos
- $U = 1$ mudeli abil tehtud prognoos on sama, mis naiivne
- $U < 1$ mudeli abil tehtud prognoos on parem, kui naiivne prognoos

Theil, H. (1966) Applied Economic Forecasting, Amsterdam: North-Holland

NÄIDE: USA tööstustoodangu indeks

USA tööstustoodangu indeks kvartalite kaupa. ip.gdt
 Modelleerimiseks kasutatud ajavahemik 1961:1 – 1998:3
 Modelleeritud indeksi logaritmi sesoonseid diferentse

Mean Error	1,1587e-008
Mean Squared Error	0,00045565
Root Mean Squared Error	0,021346
Mean Absolute Error	0,014756
Mean Percentage Error	19,809
Mean Absolute Percentage Error	15,37
Theil's U	0,93823

Prognoos parem kui naiivne

Mudel ARMA(2,0)

Mudel ARMA(2,5)

Mean Error	0,00078397
Mean Squared Error	0,00037823
Root Mean Squared Error	0,019448
Mean Absolute Error	0,012795
Mean Percentage Error	23,563
Mean Absolute Percentage Error	6,8752
Theil's U	1,035

Prognoos halvem kui naiivne