


- Előrejelzés (*predikció* vagy *extrapoláció*)
- Adatpótlás (*interpoláció*)
- Dekompozíciós vagy determinisztikus modellek.





$$X_t = T_t + S_t + C_t + Z_t \quad X_t = T_t \cdot S_t \cdot C_t \cdot Z_t$$

T_t A trendfüggvény C_t A ciklikus hatás

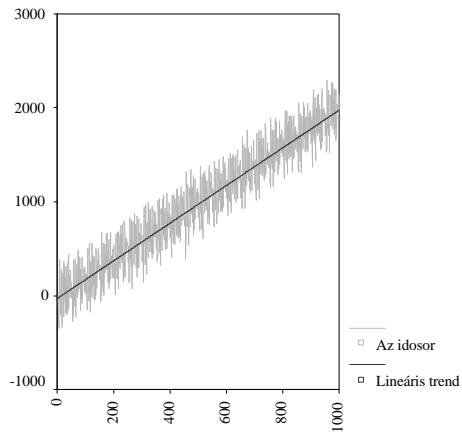
S_t A szezonális hatás Z_t A zaj (hibatag)



IDŐSORLEMEZÉS




A trendfüggvény becslése



----- Variables in the Equation -----					
Variable	B	SE B	Beta	T	Sig T
IDO	2,006954	,019975	,953956	100,474	,0000
(Constant)	-31,262314	11,541197		-2,709	,0069

Periodogram



Periódus. A maximum $p=50$

• **Simító eljárások (exponenciális szűrés)**

A simító eljárások a sztochasztikus modellezésnél egyszerűbb, áttekinthetőbb modelleket állítanak fel. A determinisztikus modellezésnél jobban figyelembe veszik az idosor véletlen jellegét, belső összefüggéseit.

• **Sztochasztikus modellek (ARIMA-modellek)**

A legárgyaltabb, legösszetettebb elemzés a *Box és Jenkins* által kidolgozott *ARIMA*-modellekben lehetséges.

Az *ARIMA*-modellek feltételeznek az idosor adatai között meglévő, valamilyen belső sztochasztikus koherenciát, ami tartósan megvan, kimutatható, és feltehetőleg a jövőbeni lefolyás során is jelen lesz.

Au

$c(k)$

A

r_k nem más, mint az X_t és X_{t+k} változók közötti parciális korrelációs együttható, azaz ezeknek az $X_{t-1}, X_{t-2}, \dots, X_{t+k}$ változókra vett lineáris regresszióinak korrelációs együtthatója.

Parciális autokorrelációs függvény (PACF):

$$\rho(1) = r(1), \quad \rho(2) = \frac{r(1) - r(1)^2}{1 - r(1)^2}, \quad \rho(k) = \frac{\det R_k^*}{\det R_k}$$

Autokovariancia függvény (AVF):

$$c(k) = \text{cov}(X_t, X_{t+k}), \quad k = 0, \pm 1, \pm 2, \dots$$

Autokorrelációs függvény (ACF):

$$r(k) = \frac{c(k)}{c(0)}, \quad k = 0, \pm 1, \pm 2, \dots$$

Parciális autokorrelációs függvény (PACF):

$$\rho(1) = r(1), \quad \rho(2) = \frac{r(1) - r(1)^2}{1 - r(1)^2}, \quad \rho(k) = \frac{\det R_k^*}{\det R_k}$$

$$X_t, Y_t, \quad t = 1, 2, \dots, N$$

keresztkovariancia függvény (CVF)

$$cvf(k) = \text{cov}(X_t, Y_{t+k})$$

keresztkorrelációs függvény (CCF)

$$ccf(k) = \frac{cvf(k)}{\sqrt{c_X(0)c_Y(0)}}$$

a jelzi, hogy a t időpillanathoz tartozó megfigyelés, milyen mélységig függ az előző időpontbeli megfigyelésektől, azaz az idosor emlékezetével kapcsolatos.

Ha $a=1$, akkor a legutolsó elem korrelálatlan az előző megfigyelésektől, azaz az idosor emlékezet nélküli.

Az $a=0$ esetén viszont az összes megelőző megfigyelés azonos erősséggel korrelál X_t -vel.

I
D
O
S
O
R
O
K

E
L
E
M
Z
É
S
E

g

Akkor szerepel ez a paraméter, ha trenddel számolunk a modellben.

Ha ***g*** közel van 1-hez, a trendfüggvényben az X_t közeli értékek nagyobb súllyal lesznek figyelembevéve, 0-közeli érték esetén pedig mindegyik érték közel azonos súllyal szerepel a trendfüggvény kiszámításában.

I
D
O
S
O
R
O
K

E
L
E
M
Z
É
S
E

d

Szezonálitási paraméter. ***d***»1 esetén a szezonálitást leíró függvény előállításában az X_t közeli értékek nagyobb súllyal lesznek figyelembevéve, ***d***»0 érték esetén pedig mindegyik érték közel azonos súllyal szerepel a szezonálitási függvény kiszámításában.

A g paraméter helyett használatos, amikor a trendfüggvény idovel lecseng.
Ha $F \gg 1$ a trend lecsengése gyors, $F \gg 0$ esetén pedig lassú.

F

EXPONENCIÁLIS SZURÉS

Az exponenciális szurési eljárás keretében több különböző paraméter kombináció beállítása mellett kiszámoljuk a

$$Q = \sum_{t=1}^T (x_t - \hat{x}_t)^2$$

négyzetes eltérést, és azt a paraméter kombinációt választjuk ki, amely mellett ez az eltérés a legkisebb.

A képletben \hat{x}_t jelöli a modell becslését a t -edik idopillanatban.

Box-Jenkins-féle idosormodellek

ARIMA(0,0,q)=MA(q) modellek:

$$X_t = b_0 e_t + b_1 e_{t-1} + b_2 e_{t-2} + \dots + b_q e_{t-q}$$

ahol $e_t, t = 1, 2, \dots, T$ fehérzaj folyamat, azaz teljesen független, normális eloszlású változók sorozata

A mozgóátlag a folyamat egy fehérzaj folyamat elemeinek lineáris kombinációjaként áll elő. X_t és X_{t-1} $q-1$ változóban közös. Az $MA(q)$ folyamat együtthatói a b_0, b_1, \dots, b_q .

Box-Jenkins-féle idősormodellek

Autoregresszív folyamatok ARIMA(p,0,0)=AR(p)

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + a_3 X_{t-3} + \dots + a_p X_{t-p} + s e_t$$

Az autoregresszív folyamat a megelőző p megfigyelt érték lineáris kombinációja és egy független e_t hiba összegeként regresszálódik. Az $AR(p)$ folyamat együtthatói az a_1, \dots, a_p, s .

Box-Jenkins-féle idosormodellek

Általános autoregresszív és mozgóátlag folyamatok,
ARIMA(p,0,q)=ARMA(p,q)

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + \dots + a_p X_{t-p} + b_0 e_t + b_1 e_{t-1} + \dots + b_q e_{t-q}$$

Integrált autoregresszív és mozgóátlag folyamatok,
ARIMA(p,d,q) modellek

derivált sor $dX_t = X_t - X_{t-1}$

második derivált sor $d^2 X_t = dX_t - dX_{t-1}$

Stb.