

# Korrelációk

6 & 7. fejezet

# Tartalom

- Időben nem változó, stohasztikus folyamatok
- Korrelációk
  - Definíció(k), rövid- és hosszútávú korrelációk
- Időbeli korrelációk gazdasági adatokban
  
- Példák

# Időben állandó folyamatok


- Mit jelent, hogy állandó? Nem változó?
  - Több definíció
- Mit jelent a korreláltság
  - Több definíció
- Eszköz: statisztikailag megfigyelhető mennyiségek, azaz kumulánsok
- Átlag v. várható érték:

$$E\{x(t)\} = \int_{-\infty}^{\infty} x \cdot PDF(x) dx$$

- Autokorrelációs függvény:

$$E\{x(t_1)x(t_2)\} = \int_{-\infty}^{\infty} x_1 x_2 PDF(x_1, x_2; t_1, t_2) dx$$

Joint PDF



# Időben állandó stohasztikus folyamatok

- Általában  $PDF(x_1, \dots, x_n; t_1, \dots, t_n)$  kell, hogy teljesen leirjunk egy folyamatot, de a gyakorlatban 2-pont függvényeket vizsgálunk
- Definíció:  $x(t)$  időben állandó stohasztikus ha a PDF-je invariáns az időbeli eltolásokra
- Példák
  - Széles értelemben vett IÁSF
    - $E\{x(t)\} = \mu$
    - $E\{x(t_1)x(t_2)\} = R(t_1, t_2) = R(t_2 - t_1) = R(\tau)$
    - $E\{x^2(t)\} = R(0) \Rightarrow$  variance  $R(0) - \mu^2$  állandó
  - Aszimptotikusan IÁSF
    - $x(t_i + c)$  független  $c$ -től nagy  $c$  értékekre
  - $N$ -ed rendű IÁSF
    - $PDF(x_1, \dots, x_n; t_1, \dots, t_n) = PDF(x_1, \dots, x_n; t_1 + c, \dots, t_n + c)$  csak  $n \leq N$  esetén igaz
  - Egy intervallumban is értelmezhető ugyanez

# Korrelációk

- $R(t_1, t_2)$  az átlagra érzékeny, ami levonható
- Autokovarianca:  $C(t_1, t_2) = R(t_1, t_2) - \mu(t_1)\mu(t_2)$
- Konstans folyamatokban  $C(\tau) = R(\tau) - \mu^2$
- Legyen most  $\mu = 0, \sigma^2 = R(0) = 1 \Rightarrow R = C$
- Tipikus időskála –  $C$  or  $R$  memóriája
- Állandó folyamatokra  $\int_0^\infty R(\tau) = \begin{cases} < \infty \\ \infty \\ \text{undet.} \end{cases}$
- Ha véges, akkor létezik  $\tau_c$  korrelációs idő

# Korrelációk – példák

- $R(\tau) = e^{\tau/\tau_0}$  memória  $\tau_c = \tau_0$
  - $R(\tau) = e^{\tau^\nu/\tau_c}$  memória  $\tau_c = \frac{\tau_0^\nu}{\nu} \Gamma\left(\frac{1}{\nu}\right)$
  - $R(\tau) \sim \tau^{\eta-1}$  ha  $0 < \eta \leq 1$   $\tau_c$  divergens
- }  $0^{th}$  approximation: there is a correlation up to  $\tau_c$

- Formálisan, poziti korrelációt feltételezve

$$E\{S_n^2\} \approx n \left( E\{n_i^2\} + 2 \underbrace{\sum_{k=1}^n E\{x_i x_{i+k}\}} \right)$$

const. rövidtávú korr.

$\infty$ , hosszútávú korr., nincs tipikus időskála

# Rövidtávú korrelációk

- Példa: Brown mozgás  $v(t)$  függvénye  $\rightarrow$  exponenciális autokorr. fv.
- A frekvenciatérben (Fourier-térben) is lehet vizsgálni

$$R(\tau) = \sigma^2 e^{-\frac{|\tau|}{\tau_c}} \Rightarrow S(f) = \mathcal{F}(R(\tau)) = \frac{2\sigma^2\tau_c}{1 + (2\pi f\tau_c)^2}$$

- Amikor  $f \ll \frac{1}{2\pi\tau_c}$  a spektrum frekvenciafüggetlen
- Időablakra ami lényegesen nagyobb, mint a  $\tau_c$  a folyamat fehérzaj
- Ennek integrálja a Wiener-folyamat aminek a spektruma

$$S(f) \sim \frac{1}{f^2}$$

# Hosszútávú korrelációk

- Hatványfüggvényyszerű autokorr. fv. → hosszútávú korrelációk

$$S(f) \sim \frac{\text{const.}}{|f|^\eta} \quad 0 < \eta < 2$$

- Sok helyen megfigyelhető
  - $\eta = 0$  : fehérzaj
  - $\eta = 2$  : Wiener-folyamat
  - $\eta \approx 1$  :  $1/f$  zaj, amit megfigyeltek diódák és tranzisztorok áramingadozásában, közlekedési jelenségekig, de minden zene és beszéd is ilyen, ld. *1/f noise in music and speech*, October 1975 Nature 258(5533):317
- A cikket [itt](#) le lehet tölteni




Fig. 3 Power spectra of pitch fluctuations,  $S_z(f)$  against  $f$ , for four radio stations: a, classical; b, jazz and blues; c, rock; d, news and talk.



# Összehasonlítás

- Ha  $\tau_c$  jellemzi a rendszert, akkor

$$f(x_1, \dots, x_{n-1}; t_1, \dots, t_{n-1} | x_n; t_n) = f(x_{n-1}; t_{n-1} | x_n; t_n)$$

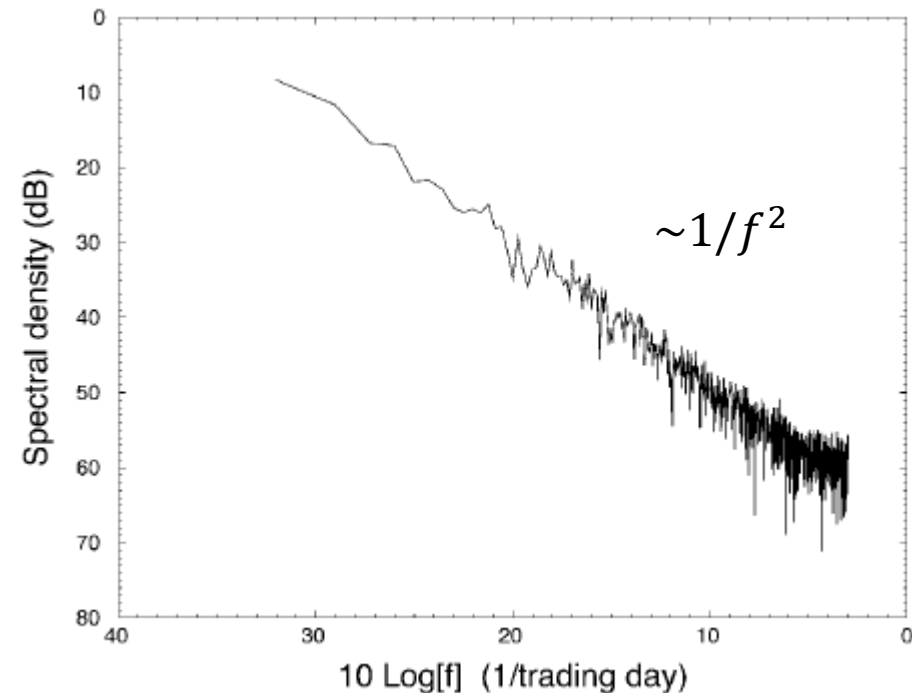
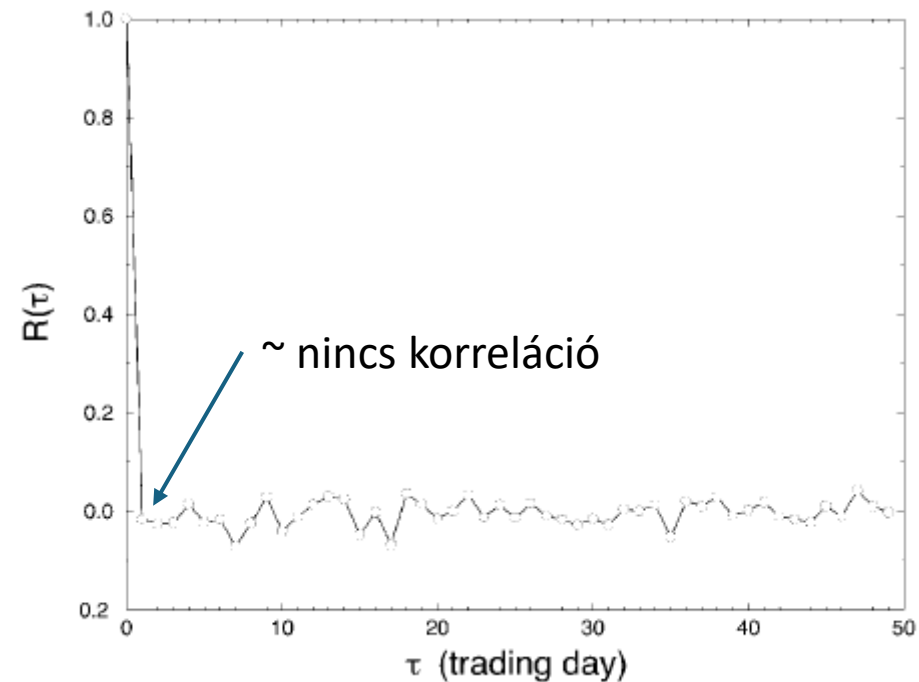

- Markov folyamat. A legegyszerűbb példa

$$f(x_1, x_2, x_3; t_1, t_2, t_3) = f(x_1, t_1) f(x_1; t_1 | x_2; t_2) f(x_2; t_2 | x_3; t_3)$$

- Vagyis első- és másodrendű feltételes valószínűségek jellemzik a folyamatokat. Olyan folyamatok amelyekben nincs tipikus időskála, nem Markov folyamatok.
- A nem-markovi folyamatok esetén minden rendű valószínűség kell
- Fontos következmény, hogy különböző  $1/f$  zajok nem tudhatók be ugyanannak a folyamatnak, hacsak nem tudunk többet.

# Gazdasági adatok

- Autokorreláció és spektrum
  - Az ár logaritmusának időbeli mozgása
- Véletlen séta vagyis fehér zaj szerű viselkedés látszik
- A korrelációs hossz kevesebb, mint egy kereskedelmi nap
- Gyakori méréssel kereskedelmi perc szintű korreláció kimutatható



# Egyéb eszközök

- Az autokorrelációs fv. és a spektrum nem túl érzékeny a hosszú távú korrelációkra
- A szórás időfejlődése többet árul el
- Általában  $\sigma(t) \sim t^\nu$  ahol  $\nu = 1/2$  ha a árak függetlenek
- „recent investigation” : 30 kereskedelmi perctől 100 kereskedelmi napig terjedő időablakban:  $\nu \approx 0.5$
- Piacfüggő lehet. Más vizsgálatok szerint:
  - New York Composite Index:  $\nu \approx 0.52$
  - DAX index:  $\nu \approx 0.53$
  - MIB index:  $\nu \approx 0.57$
- HF S&P500 data  $t < 30$  perc, superdiffuse  $\nu \approx 0.8$
- Hosszabb távon  $\nu = 0.53$

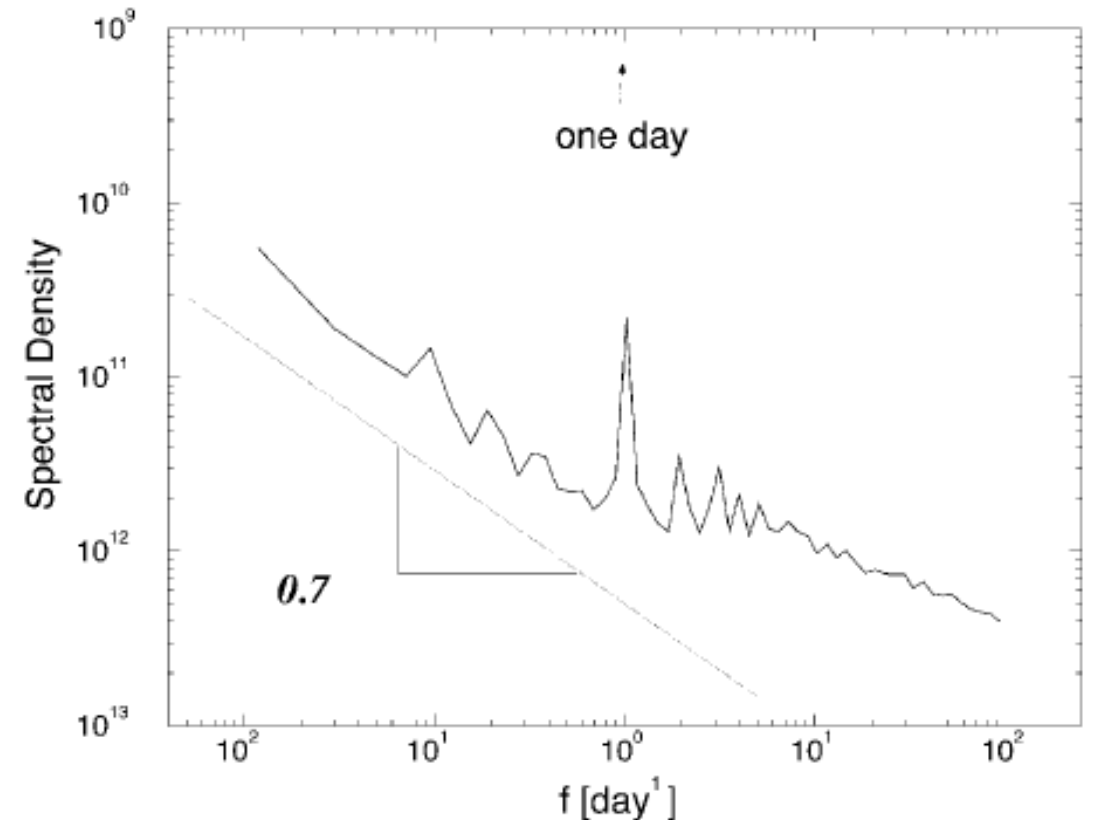

Gyenge hosszútávú korreláció  
Nagyobb  $\nu$  a kevésbé hatékony piacoknál

# Magasabb rendű korrelációk – volatilitás

- A páronkénti árkülönbség rövid távú memóriával rendelkezik
- Ugyanakkor nem-lineáris függvények szerinti kombinációk már nem
- Más alapvető stoch. foly. lehet : volatilitás → szórás egy időablakban
- Más módszerekkel is lehet becsülni
- Miért érdekes:
  - Összeköthető a piacba adott időben érkező információ mennyiségével
    - Ha jön infó, megváltozik a kereskedés → nagy volatilitás
  - Később tárgyalandó modellekben lehet használni
  - A gyakorlatban egy fontos paraméter a befektetések kockázatának meghatározásában

# Magasabb rendű korrelációk – volatilitás

- A volatilitás autokorrelációs függvénye jól leírható hatványfüggvénnyel
- A spektrum is jól jellemezheti a hosszútávú korrelációkat
- Nincs ellentmondás: ezek magasabb rendű valószínűségek






# Összefoglalás

- Az árak stochasztikus dinamikája: véletlen bolyongás, rövidtávú korr.
- Leírhatóak az árváltozások időben állandó folyamatként?
- Empiria: nem, mert a volatilitás időfüggő
- Aszimptotikusan, nagy idősorokat vizsgálva, időben állandó
  
- Láttuk tehát:
  - Az árváltozások páronként korrelálatlanok
  - A rövidtávú memória néhány perc hosszú
  - Gyenge hosszútávú korreláció megfigyelhető a szórás időfejlődésében
  - A volatilitás hosszútávon,  $1/f$  szerű spektrummaé korrelált




## Saját példa

- Erzsébet tér CO mérés
- Napi mintavétel
- Időtolás (lag) 2, 5, 20 nap



## Saját példa

- Erzsébet tér CO mérés
- Órás mintavétel
- Időtolás (lag) 10, 70, 200 óra





```
import statsmodels.api as sm
from statsmodels.graphics import tsaplots
import matplotlib.pyplot as plt

#define data
x =
[278,277,251,262,268,297,284,289,305,306,304,304,265,257,270,266,308,285,302,277,300,347,370,337,375,469,345,297,285,303,301,303,304,306,264,2
55,234,223,218,234,248,218,232,221,237,310,345,285,298,312,296,286,262,281,329,364,483,361,325,306,287,300,306,255,291,304,298,216,242,271,23
5,223,252,227,229,222,230,241,231,294,338,284,285,320,267,244,223,213,212,212,218,220,217,253,248,254,280,234,226,237,240,246,264,322,394,337,
357,311,244,232,211,205,205,229,203,215,226,252,260,258,284,291,290,284,260,270,308,454,488,380,312,278,238,242,191,197,202,235,216,245,253,2
77,406,391,381,439,294,259,248,264,227,404,282,297,282,234,197,199,165,205,125,117,142,180,183,183,227,242,206,282,271,162,216,222,210,338,29
9,186,171,172,146,115,116,134,166,144,146,121,154,202,324,497,546,384,311,163,146,165,131,142,140,129,104,81,61,76,105,95,117,119,114,136,152,
179,192,215,192,151,116,102,104,122,125,146,206,223,224,252,194,246,240,187,192,268,205,217,193,142,159,138,125,118,122,115,120,118,126,144,1
93,188,196,175,148,128,124,103,103,103,98,92,103,126,132,142,141,138,117,120,117,130,140,151,203,269,230,221,216,175,154,181,167,165,165,169,1
66,172,182,188,177,180,173,176,169,171,173,254,265,304,269]
print(len(x))
y = [296,281,295,248,258,295,233,222,152,178,132,171,252,291,323,267,313,351,377,414,371,355,341,325,316,342,317,336,342,337,237]
#calculate autocorrelations
sm.tsa.acf(y)

#plot autocorrelation function
fig = tsaplots.plot_acf(y, lags=20)
plt.show()
```