

ARMA modely
část 1: autoregresné modely (AR)

Beáta Stehlíková

Časové rady, FMFI UK, 2011/2012

ARMA modely

- Terminológia:
 - ◇ **AR - autoregresný model** - niekoľko nasledujúcich hodín
 - ◇ MA - moving average, kĺzavé priemery
 - ◇ ARMA - ich kombinácia
- Najskôr: **autoregresný proces prvého rádu - AR(1)**
 - ◇ definícia
 - ◇ stacionarita, ohraničenie na parametre
 - ◇ výpočet momentov a ACF
 - ◇ simulované dáta
 - ◇ praktický príklad s reálnymi dátami
- Potom:
 - ◇ autoregresné procesy vyšších rádov
 - ◇ ako určiť vhodný rád procesu pre dané dáta

I.

Autoregresný proces prvého rádu - AR(1)

AR(1) - definícia

- AR(1) proces:

$$x_t = \delta + \alpha x_{t-1} + u_t,$$

kde δ a α sú konštanty a $\{u_t\}$ je biely šum

- Nech pre $t = t_0$ je daná hodnota x_{t_0} :

$$x_{t_0+1} = \delta + \alpha x_{t_0} + u_{t_0+1},$$

$$x_{t_0+2} = \delta + \alpha x_{t_0+1} + u_{t_0+2} =$$

$$\delta(1 + \alpha) + \alpha^2 x_{t_0} + (\alpha u_{t_0+1} + u_{t_0+2}),$$

$$x_{t_0+3} = \dots$$

vo všeobecnosti:

$$(1) \quad x_{t_0+\tau} = \alpha^\tau x_{t_0} + \frac{1 - \alpha^\tau}{1 - \alpha} \delta + \sum_{j=0}^{\tau-1} \alpha^j u_{t_0+\tau-j}$$

AR(1) - stacionarita

- Zo vzťahu (1):

$$x_t = \alpha^{t-t_0} x_{t_0} + \frac{1 - \alpha^{t-t_0}}{1 - \alpha} \delta + \sum_{j=0}^{t-t_0-1} \alpha^j u_{t-j}$$

- **Deterministické začiatkové podmienky:** hodnota procesu v čase t_0 je x_{t_0} → proces nie je stacionárny
- **Náhodné začiatkové podmienky:**

◇ Proces je generovaný pre $t \in \mathbb{R}$ → hodnota x_{t_0} je náhodná.

◇ Ak $-1 < \alpha < 1$, tak pre $t_0 \rightarrow -\infty$ dostaneme

$$(2) \quad x_t = \frac{1}{1 - \alpha} \delta + \sum_{j=0}^{\infty} \alpha^j u_{t-j}$$

◇ Woldova reprezentácia: $\psi_j = \alpha^j$ pre $|\alpha| < 1$ → proces je slabo stacionárny.

AR(1) - výpočet pomocou operátora L

- Zápis procesu:

$$(1 - \alpha L)x_t = \delta + u_t$$

- Vyjadríme x_t :

$$x_t = (1 - \alpha L)^{-1}\delta + (1 - \alpha L)^{-1}u_t$$

- Výpočet inverzného operátora - čo je $(1 - \alpha L)^{-1}$ (píše sa aj $1/(1 - \alpha L)$)?

$$(1 - \alpha L)^{-1} = \phi_0 + \phi_1 L + \phi_2 L^2 + \dots$$

$$(1 - \alpha L)(\phi_0 + \phi_1 L + \phi_2 L^2 + \dots) = 1$$

Roznásobíme a porovnáme koeficienty $\rightarrow \phi_j = \alpha^j$, t. j.

$$(1 - \alpha L)^{-1} = \frac{1}{1 - \alpha L} = 1 + \alpha L + \alpha^2 L^2 + \alpha^3 L^3 + \dots$$

AR(1) - výpočet pomocou operátora L

- Teda:

$$\begin{aligned}x_t &= (1 + \alpha L + \alpha^2 L^2 + \dots)\delta + (1 + \alpha L + \alpha^2 L^2 + \dots)u_t \\ &= (1 + \alpha + \alpha^2 + \dots)\delta + (u_t + \alpha u_{t-1} + \alpha^2 u_{t-2} + \dots) \\ &= \frac{\delta}{1 - \alpha} + \sum_{j=0}^{\infty} \alpha^j u_{t-j},\end{aligned}$$

pričom na sčítanie nekonečného radu potrebujeme splnenie podmienky $|\alpha| < 1$.

- Z oboch postupov teda vypláva **podmienka stacionarity pre AR(1) proces: $|\alpha| < 1$**
- V ďalších výpočtoch predpokladáme splnenie tejto podmienky

AR(1) - momenty, postup 1

- Pripomeňme si explicitné vyjadrenie procesu (2):

$$x_t = \frac{\delta}{1 - \alpha} + \sum_{j=0}^{\infty} \alpha^j u_{t-j}$$

- Stredná hodnota:

$$\begin{aligned} E[x_t] &= E \left[\frac{\delta}{1 - \alpha} + \sum_{j=0}^{\infty} \alpha^j u_{t-j} \right] \\ &= \frac{\delta}{1 - \alpha} + \sum_{j=0}^{\infty} \alpha^j E[u_{t-j}] = \frac{\delta}{1 - \alpha} \end{aligned}$$

- ◇ $E[x_t] = 0$ práve vtedy, keď $\delta = 0$
- ◇ vo všeobecnosti $E[x_t] \neq \delta$, ale majú rovnaké znamienko (lebo $|\alpha| < 1$)

AR(1) - momenty, postup 1

- Variancia:

$$\begin{aligned} \text{Var}[x_t] &= \text{Var} \left[\frac{\delta}{1 - \alpha} + \sum_{j=0}^{\infty} \alpha^j u_{t-j} \right] \\ &= \sum_{j=0}^{\infty} \text{Var}[\alpha^j u_{t-j}] = \sum_{j=0}^{\infty} \alpha^{2j} \text{Var}[u_{t-j}] \\ &= \sigma^2 \sum_{j=0}^{\infty} \alpha^{2j} = \sigma^2 \frac{1}{1 - \alpha^2} \end{aligned}$$

kde

- ◇ sme využili, že disperzia súčtu nekorelovaných premenných je súčet disperzií
- ◇ σ^2 je variancia bieleho šumu $\{u_j\}$

AR(1) - momenty, postup 1

- **Autokovariancie** (využijeme, že $Cov[u_k, u_l] = \sigma^2$ pre $k = l$ a $Cov[u_k, u_l] = 0$ pre $k \neq l$):

$$\begin{aligned} Cov[x_t, x_{t-s}] &= E \left[\left(\sum_{i=0}^{\infty} \alpha^i u_{t-i} \right) \left(\sum_{j=0}^{\infty} \alpha^j u_{t-s-j} \right) \right] \\ &= \sum_{i=0}^{\infty} \sum_{j=0}^{\infty} \alpha^{i+j} E[u_{t-i} u_{t-s-j}] \\ &= \sigma^2 \sum_{j=0}^{\infty} \alpha^{s+2j} = \alpha^s \frac{\sigma^2}{1 - \alpha^2} \end{aligned}$$

- **Autokorelácie** :

$$Cor[x_t, x_{t-s}] = \frac{Cor[x_t, x_{t-s}]}{Var[x_t]Var[x_{t-s}]} = \alpha^s$$

AR(1) - momenty, postup 2

- Alternatívny postup, nevyužívajúci explicitné vyjadrenie x_t ; užitočný pri procesoch vyššieho rádu
- Stredná hodnota:
 - ◇ vieme, že existuje konštanta μ , taká že $E[x_t] = \mu$ pre každé t (stacionarita)
 - ◇ spravíme strednú hodnotu ľavej aj pravej strany rovnosti z definície procesu:

$$\begin{aligned}x_t &= \delta + \alpha x_{t-1} + u_t & / & E[.] \\ \mu &= \delta + \alpha \mu + 0 \\ \mu &= \frac{\delta}{1 - \alpha}\end{aligned}$$

AR(1) - momenty, postup 2

- Disperzia a autokovariancie:

- ◇ ak x_t je stacionárny proces (nielen AR(1)), tak procesy x_t a $x_t - \mu$ majú rovnaké disperzie a autokovariancie
- ◇ pre AR(1) proces teda môžeme predpokladať, že $\delta = 0$
- ◇ nech $s \geq 0$:

$$x_t = \alpha x_{t-1} + u_t \quad / \quad \times x_{t-s}, E[.]$$

$$E[x_t x_{t-s}] = \alpha E[x_{t-1} x_{t-s}] + E[u_t x_{t-s}]$$

z toho:

$$(3) \quad s = 0 \Rightarrow \gamma(0) = \alpha\gamma(1) + \sigma^2$$

$$(4) \quad s = 1 \Rightarrow \gamma(1) = \alpha\gamma(0)$$

$$(5) \quad s \geq 2 \Rightarrow \gamma(s) = \alpha\gamma(s-1)$$

AR(1) - momenty, postup 2

- **Disperzia a autokovariancie**- pokračovanie:

- ◇ (3) a (4) - dve lineárne rovnice s dvoma neznámymi \rightarrow vyjadríme $\gamma(0), \gamma(1)$:

$$(6) \quad \gamma(0) = \frac{\sigma^2}{1 - \alpha^2}, \quad \gamma(1) = \frac{\alpha\sigma^2}{1 - \alpha^2}$$

- ◇ (5) je potom rekurentný predpis, pričom (6) dáva začiatočnú podmienku:

$$(7) \quad \gamma(1) = \frac{\alpha\sigma^2}{1 - \alpha^2}$$

$$(8) \quad \gamma(s + 1) = \alpha\gamma(s) \text{ pre } s \geq 1$$

- **Autokorelácie**: rovnice (7) a (8) vydelíme $\gamma(0)$:

$$\rho(1) = \alpha, \quad \rho(s + 1) = \alpha\rho(s) \text{ pre } s \geq 1$$

a teda $\rho(s) = \alpha^s$.

Príklad - simulované dáta

- AR(1) proces




$$x_t = \delta + \alpha x_{t-1} + u_t,$$

kde biely šum u_t má normálne rozdelenie, $\delta = 0$,
 $\sigma^2 = 1$

- Postupne zoberieme $\alpha = \{0.9, 0.6, -0.9\}$
- Zobrazíme:
 - ◇ realizáciu procesu
 - ◇ teoretickú autokorelačnú funkciu
 - ◇ výberovú autokorelačnú funkciu odhadnutú z dát




Príklad - simulované dáta, $\alpha = 0.9$

$$x_t = 0.9 x_{t-1} + u_t, \quad u_t \sim N(0,1) \text{ nezávisle}$$






Príklad - simulované dáta, $\alpha = 0.6$

$$x_t = 0.6 x_{t-1} + u_t, \quad u_t \sim N(0,1) \text{ nezávisle}$$




Príklad - simulované dáta, $\alpha = -0.9$

$$x_t = -0.9 x_{t-1} + u_t, \quad u_t \sim N(0,1) \text{ nezávisle}$$



Príklad - reálne dáta

- G. Kirchgässner: **Causality Testing of the Popularity Function: An Empirical Investigation for the Federal Republic of Germany, 1971-1982**, Public Choice 45 (1985), p. 155-173.
- [Kirchgässner, Wolters], example 2.2
- Nemecko, január 1971 - apríl 1982
- CDU_t = volebné preferencie CDU/CSU



a) Popularity of the CDU/CSU, 1971 – 1982

Príklad - reálne dáta


- Odhadnutý AR(1) model:

$$\text{CDU}_t = 8.053 + 0.834 \text{CDU}_{t-1} + \hat{u}_{t^s}$$

(3.43) (17.10)

$$\bar{R}^2 = 0.683, \text{ SE} = 1.586, \underline{Q(11) = 12.516} \text{ (p} = 0.326\text{)}.$$

The estimated t values are given in parentheses. The autocorrelogram, which is also given in *Figure 2.4*, does not indicate any higher-order process. Moreover, the Box-Ljung Q Statistic with 12 correlation coefficients (i.e. with 11 degrees of freedom) gives no reason to reject this model.



Príklad - reálne dáta

- Otázky k odhadnutému modelu:
 - ◇ Je odhadnutý model stacionárny?
 - ◇ V texte sa spomínajú autokorelácie rezíduí a Ljung-Boxova Q štatistika - aké hypotézy sa testujú (a prečo), akým spôsobom a s akými závermi?
 - ◇ Na grafe sú pri autokoreláciách zostrojené intervaly. Vypočítajte pomocou známych údajov ich hranice.
 - ◇ Čomu sa rovná stredná hodnota premennej CDU_t ?

II.

Autoregresný proces druhého rádu - AR(2)

AR(2) - definícia

- AR(2) proces:

$$x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t$$

- Pomocou operátora posunu:

$$(1 - \alpha_1 L - \alpha_2 L^2)x_t = \delta + u_t$$

$$\alpha(L)x_t = \delta + u_t$$

- Woldova reprezentácia a stacionarita:

$$x_t = \alpha^{-1}(L)\delta + \alpha^{-1}(L)u_t$$

→ potrebujeme inverzný operátor $\alpha^{-1}(L)$; znovu ho nájdeme **metódou neurčitých koeficientov**:

$$\alpha^{-1}(L) = \psi_0 + \psi_1 L + \psi_2 L^2 + \dots$$

pričom

$$(9) \quad 1 = (1 - \alpha_1 L - \alpha_2 L^2)(\psi_0 + \psi_1 L + \psi_2 L^2 + \dots)$$

AR(2) - stacionarita

- Porovnáme koeficienty pri L^j na oboch stranách (9):

$$\psi_j - \alpha_1\psi_{j-1} - \alpha_2\psi_{j-2} = 0,$$

$$\psi_0 = 1, \psi_1 = \alpha_1$$

- **Podmienka stacionarity:** Kvôli splneniu podmienky $\sum \psi_j^2 < \infty$ musia byť korene charakteristickej rovnice

$$\lambda^2 - \alpha_1\lambda - \alpha_2 = 0$$

v absolútnej hodnote menšie ako 1

- Inak povedané: **korene rovnice**

$$\alpha(L) = 1 - \alpha_1L - \alpha_2L^2 = 0$$

musia byť v absolútnej hodnote väčšie ako 1, t. j.

mimo jednotkového kruhu

- To isté vyšlo predtým pre AR(1): koreň $\alpha(L) = 0$ mimo jednotkového kruhu

AR(2) - momenty

- Slabo stacionárny AR(2) proces:

$$x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t$$

- Stredná hodnota:

- ◇ označme $\mu = E[x_i]$; potom

$$\mu = \delta + \alpha_1 \mu + \alpha_2 \mu,$$

$$\mu = \frac{\delta}{1 - \alpha_1 - \alpha_2}$$

- ◇ Podobne ako pre AR(1): stredná hodnota sa nerovná parametru δ (okrem prípadu $\delta = 0$), ale majú rovnaké znamienko

AR(2) - momenty

- **Autokovariancie:** znovu môžeme predpokladať nulovú strednú hodnotu, t. j.

$$x_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t \quad / \quad \times x_{t-s}, E[.]$$

$$E[x_{t-s}x_t] = \alpha_1 E[x_{t-s}x_{t-1}] + \alpha_2 E[x_{t-s}x_{t-2}] + E[x_{t-s}u_t]$$

- Pre $s = 0, 1, 2$ dostaneme:

$$\gamma(0) = \alpha_1 \gamma(1) + \alpha_2 \gamma(2) + \sigma^2$$

$$\gamma(1) = \alpha_1 \gamma(0) + \alpha_2 \gamma(1)$$

$$\gamma(2) = \alpha_1 \gamma(1) + \alpha_2 \gamma(0)$$

- sústava rovníc $\rightarrow \gamma(0) = Var[x_t], \gamma(1), \gamma(2)$

- Pre $s \geq 2$ - diferenčná rovnica:

$$(10) \quad \gamma(s) - \alpha_1 \gamma(s-1) - \alpha_2 \gamma(s-2) = 0,$$

začiatkové podmienky z predchádzajúceho bodu

AR(2) - momenty

- **Autokorelácie:** diferenčnú rovnicu (10) a jej začiatočné podmienky vydelíme $\gamma(0)$:

$$\rho(s) - \alpha_1\rho(s-1) - \alpha_2\rho(s-2) = 0$$

$$\rho(0) = 1, \rho(1) = \frac{\alpha_1}{1 - \alpha_2}$$

AR(2) - príklady

1. Proces: $x_t = 1 + 1.5x_{t-1} - 0.56x_{t-2} + u_t$

- korelácie spĺňajú diferenčnú rovnicu

$$\rho(t) - 1.5\rho(t-1) + 0.56\rho(t-2) = 0,$$

ktorá má všeobecné riešenie

$$\rho(t) = c_1(0.8)^t + c_2(0.7)^t$$

- ACF monotónne klesá

2. Proces: $x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$

- korelácie spĺňajú diferenčnú rovnicu

$$\rho(t) - 1.4\rho(t-1) + 0.85\rho(t-2) = 0,$$




ktorá má všeobecné riešenie

$$\rho(t) = 0.922^t (c_1 \cos(0.709t) + c_2 \sin(0.709t))$$

- ACF osciluje




AR(2) - príklad 1

$$x_t = 1 + 1.5 x_{t-1} - 0.56 x_{t-2} + u_t, \quad u_t \sim N(0,1) \text{ nezávisle}$$



AR(2) - príklad 2

$$x_t = 1.4 x_{t-1} - 0.85 x_{t-2} + u_t, \quad u_t \sim N(0,1) \text{ nezávisle}$$




$$\cos(kt), \sin(kt) \rightarrow \text{perióda } \frac{2\pi}{k} = 8.862 \approx 9$$

AR(2) - reálne dáta

[Kirchgässner, Wolters], example 2.6

- 3-mesačná úroková miera, Nemecko, 1970q1-1998q4




AR(2) - reálne dáta

- Odhadnutý AR(2) model:

$$\text{GSR}_t = 0.577 + 1.407 \text{GSR}_{t-1} - 0.498 \text{GSR}_{t-2} + \hat{u}_t$$

(2.82) (17.49) (-6.16)

$$\bar{R}^2 = 0.910, \text{ SE} = 0.812, Q(6) = 6.431 \text{ (p} = 0.377\text{)}$$



c) Estimated autocorrelation function of the residuals of the estimated AR(2) process with confidence intervals

AR(2) - reálne dáta

- Otázky k odhadnutému modelu:
 - ◇ Je stacionárny?
 - ◇ Analyzujte rezíduá - autokorelogram, Q-štatistika.
 - ◇ Aká je stredná hodnota odhadnutého procesu?
Aký je priebeh jeho autokorelačnej funkcie?

III.

Autoregresný proces p -teho rádu - $AR(p)$

AR(p) proces - stacionarita

- AR(p) proces:

$$(11) \quad x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \dots + \alpha_p x_{t-p} + u_t,$$

t. j. $\alpha(L)x_t = \delta + u_t$, kde $\alpha(L) = 1 - \alpha_1 L - \dots - \alpha_p L^p$

- Woldova reprezentácia a stacionarita:

$$x_t = \alpha(L)^{-1}(\delta + u_t),$$

inverzný operátor $\alpha(L)^{-1}$ hľadáme v tvare

$$\alpha(L)^{-1} = 1 + \psi_1 L + \psi_2 L^2 + \dots$$

- Pre koeficienty ψ_j dostaneme diferenčnú rovnicu

$$\psi_k - \alpha_1 \psi_{k-1} - \dots - \alpha_p \psi_{k-p} = 0$$

\Rightarrow kvôli konv. $\sum \psi_j^2$ musia byť korene charakt. rovnice

$\lambda^k - \alpha_1 \lambda^{k-1} - \dots - \alpha_p = 0$ vnútri jednotkového kruhu,

t. j. korene $\alpha(L) = 0$ musia byť mimo jednotkového kruhu

AR(p) proces - momenty

- **Stredná hodnota:**

označíme $\mu = E[x_t]$ a spravíme strednú hodnotu z ľavej aj pravej strany (11):

$$\mu = \delta + \alpha_1\mu + \dots + \alpha_p\mu \Rightarrow \mu = \frac{\delta}{1 - \alpha_1 - \dots - \alpha_p}$$

aj teraz: stredná hodnota má rovnaké znamienko ako parameter δ

- **Variancia, autokovariancie** - nech $\delta = 0$

$$x_t = \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t \quad / \quad \times x_{t-s}, E[.]$$
$$\gamma(s) = \alpha_1 \gamma(s-1) + \dots + \alpha_p \gamma(s-p) + E[u_t x_{t-s}]$$

AR(p) proces - momenty

- Variancia, autokovariancie - pokračovanie:
 - ◇ $s = 0, 1, \dots, p \rightarrow$ sústava $p + 1$ rovníc s neznámymi $\gamma(0), \gamma(1), \dots, \gamma(p)$:

$$\gamma(0) = \alpha_1\gamma(1) + \alpha_2\gamma(2) + \dots + \alpha_p\gamma(p) + \sigma^2$$

$$\gamma(1) = \alpha_1\gamma(0) + \alpha_2\gamma(1) + \dots + \alpha_p\gamma(p-1)$$

...

$$\gamma(p) = \alpha_1\gamma(p-1) + \alpha_2\gamma(p-2) + \dots + \alpha_p\gamma(0)$$

(12)

- ◇ ostatné autokovariancie z diferenčnej rovnice

$$(13) \quad \gamma(t) - \alpha_1\gamma(t-1) - \dots - \alpha_p\gamma(t-p) = 0$$

AR(p) proces - momenty

- **ACF :**

- ◇ diferenčná rovnica pre autokorelácie - rovnicu (13) vydelíme disperziou $\gamma(0)$:

$$\rho(t) - \alpha_1\rho(t-1) - \dots - \alpha_p\rho(t-p) = 0$$

- ◇ začiatočné podmienky - posledných p rovníc zo sústavy (12) vydelíme $\gamma(0)$:

$$\rho(1) = \alpha_1 + \alpha_2\rho(1) + \dots + \alpha_p\rho(p-1)$$

$$\rho(2) = \alpha_1\rho(1) + \alpha_2 + \dots + \alpha_p\rho(p-2)$$

...

$$\rho(p) = \alpha_1\rho(p-1) + \alpha_2\rho(p-2) + \dots + \alpha_p$$

(14)



- nazývajú sa **Yule-Wolkerove rovnice**

IV.

Parciálna autokorelačná funkcia - určovanie rádu AR procesu

PACF - motivácia

- Prečo sme na modelovanie preferencií použili AR(1) model a na modelovanie úrokovej miery AR(2)?
- Teoretická ACF pre AR(1) a AR(2) procesy z predchádzajúcich simulácií:



Ako ich rozlíšiť?

- Ako zistiť vhodnosť AR modelu určit' jeho rád?

PACF - motivácia

- Uvažujme nejaký náhodný proces x_t s nulovou strednou hodnotou a modelujme jeho hodnotu pomocou prechádzajúcich k hodnôt:

$$x_t = \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \beta_k x_{t-k} + u_t$$

- Označme koeficienty Φ_{ki} , kde k je počet použitých starších hodnôt procesu x a i je koeficient pri x_{t-i}
- Teda:

$$x_t = \Phi_{11} x_{t-1} + u_t$$

$$x_t = \Phi_{21} x_{t-1} + \Phi_{22} x_{t-2} + u_t$$

$$x_t = \Phi_{31} x_{t-1} + \Phi_{32} x_{t-2} + \Phi_{33} x_{t-3} + u_t$$

...

$$x_t = \Phi_{k1} x_{t-1} + \Phi_{k2} x_{t-2} + \Phi_{k3} x_{t-3} + \dots + \Phi_{kk} x_{t-k} + u_t$$

- Ak x je AR(p) proces, tak $\Phi_{kk} = 0$ pre $k > p$.

PACF - definícia a výpočet

- Koeficient Φ_{kk} sa nazýva **parciálna autokorelácia rádu k**
- Postupnosť týchto koeficientov vytvára **parciálnu autokorelačnú funkciu (PACF)**
- Výpočet: vyjdeme zo vzťahu

$$x_t = \Phi_{k1}x_{t-1} + \Phi_{k2}x_{t-2} + \Phi_{k3}x_{t-3} + \dots + \Phi_{kk}x_{t-k} + u_t$$

a rovnako ako pri odvodení Yule-Wolkerovych rovníc dostaneme

$$\rho(1) = \Phi_{k1} + \Phi_{k2} \rho(1) + \dots + \Phi_{kk} \rho(k-1)$$

$$\rho(2) = \Phi_{k1} \rho(1) + \Phi_{k2} + \dots + \Phi_{kk} \rho(k-2)$$

...

$$\rho(k) = \Phi_{k1} \rho(k-1) + \Phi_{k2} \rho(k-2) + \dots + \Phi_{kk}$$

PACF - definícia a výpočet

- Maticový zápis:

$$\begin{bmatrix} 1 & \rho(1) & \dots & \rho(k-1) \\ \rho(1) & 1 & \dots & \rho(k-2) \\ & & \dots & \\ \rho(k-1) & \rho(k-2) & \dots & 1 \end{bmatrix} \begin{bmatrix} \Phi_{k1} \\ \Phi_{k2} \\ \dots \\ \Phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho(1) \\ \rho(2) \\ \dots \\ \rho(k) \end{bmatrix}$$

- Zaujímá nás iba Φ_{kk} , použijeme Cramerovo pravidlo:


$$(15) \quad \Phi_{kk} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \dots & \rho(1) \\ \rho(1) & 1 & \dots & \rho(2) \\ & & \dots & \\ \rho(k-1) & \rho(k-2) & \dots & \rho(k) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & \dots & \rho(k-1) \\ \rho(1) & 1 & \dots & \rho(k-2) \\ & & \dots & \\ \rho(k-1) & \rho(k-2) & \dots & 1 \end{pmatrix}}$$

PACF - príklad: AR(1) proces

- Postupne počítame:

$$\begin{aligned}\Phi_{11} &= \rho(1) \\ \Phi_{22} &= \frac{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & \rho(2) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & 1 \end{pmatrix}} = \frac{\rho(2) - \rho(1)^2}{1 - \rho(1)^2} = 0 \\ &\dots\end{aligned}$$

- Pre $\alpha = 0.9$:

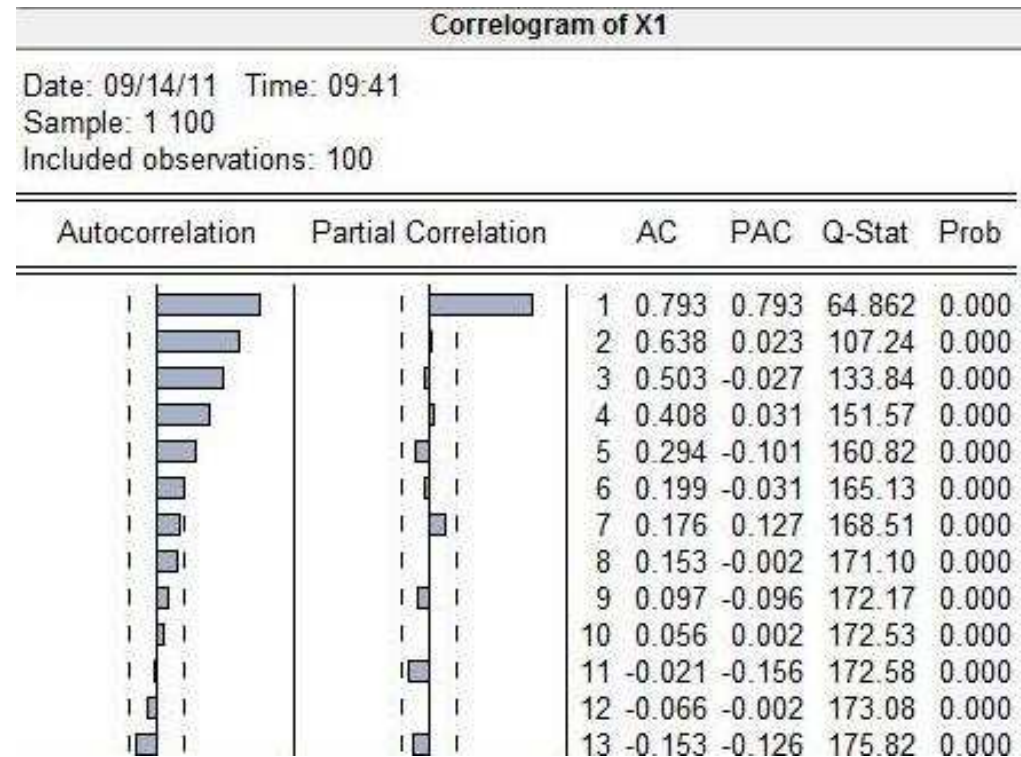


PACF - odhadovanie z dát

- Za teoretické autokorelácie vo vzťahu (15) dosadíme ich konzistentné odhady \rightarrow dostaneme konzistentný odhad $\hat{\Phi}_{kk}$
- Pre AR(p) proces je $\Phi_{kk} = 0$ pre $k > p$, pre tieto k asymptoticky platí

$$Var[\hat{\Phi}_{kk}] \approx \frac{1}{T}$$

Príklad: simulované dáta (1)



Z odhadnutej ACF a PACF usúdime, že dáta boli zrejme generované AR(1) procesom.

Príklad: simulované dáta (1)

Odhadneme AR(1) model:

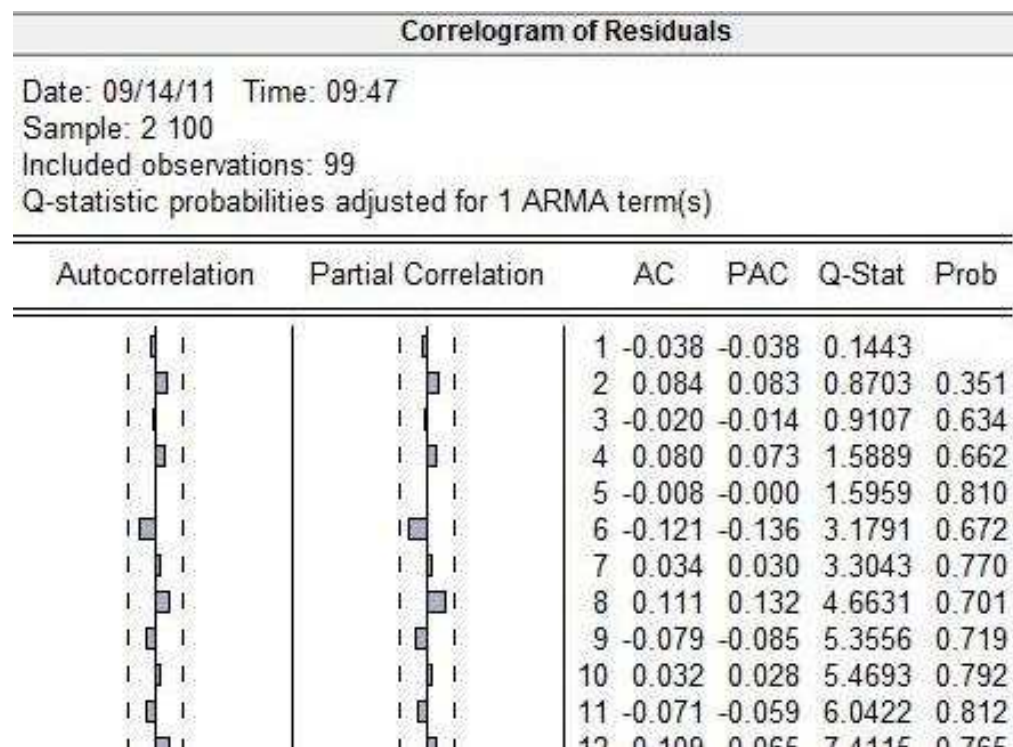
Dependent Variable: X1
Method: Least Squares
Date: 09/14/11 Time: 09:44
Sample (adjusted): 2 100
Included observations: 99 after adjustments
Convergence achieved after 3 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5.062255	0.481641	10.51044	0.0000
AR(1)	0.793600	0.060654	13.08403	0.0000
R-squared	0.638318	Mean dependent var	4.990404	
Adjusted R-squared	0.634590	S.D. dependent var	1.633787	
S.E. of regression	0.987611	Akaike info criterion	2.832939	
Sum squared resid	94.61140	Schwarz criterion	2.885366	
Log likelihood	-138.2305	F-statistic	171.1917	
Durbin-Watson stat	2.076048	Prob(F-statistic)	0.000000	
Inverted AR Roots	.79			

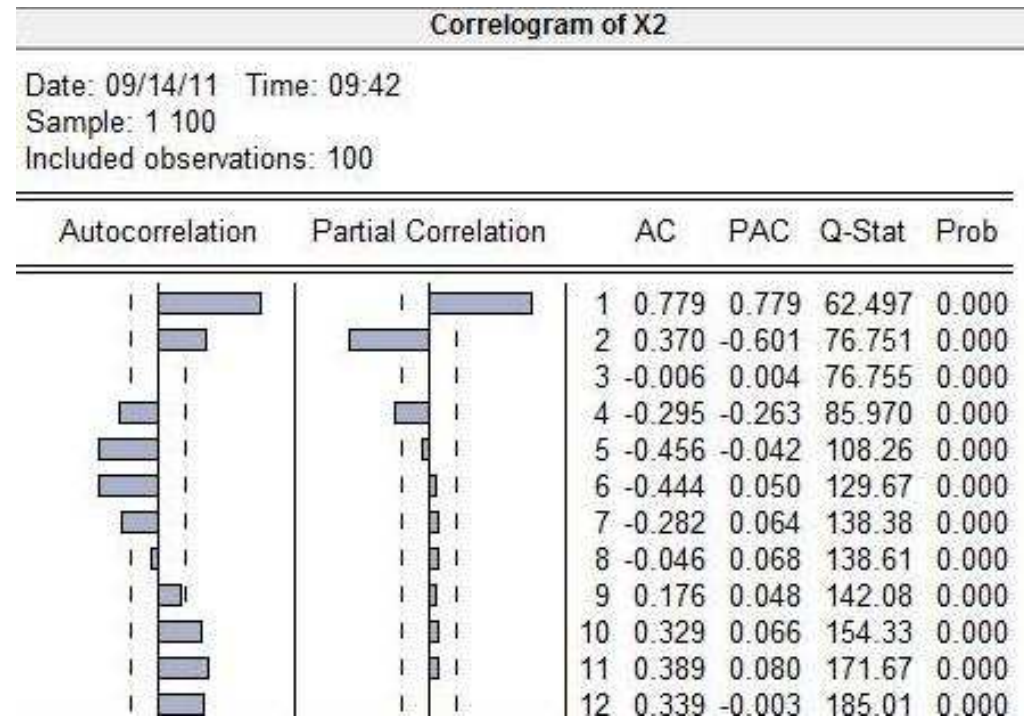
Príklad: simulované dáta (1)

Získaný model

- je stacionárny
- má dobré rezíduá:



Príklad: simulované dáta (2)



→ dáta vyzerajú na AR(2) proces

Príklad: simulované dáta (2)

Odhadneme AR(2) model:

Dependent Variable: X2
Method: Least Squares
Date: 09/14/11 Time: 09:44
Sample (adjusted): 3 100
Included observations: 98 after adjustments
Convergence achieved after 3 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.597631	0.285055	5.604647	0.0000
AR(1)	1.446250	0.067725	21.35463	0.0000
AR(2)	-0.764615	0.068891	-11.09894	0.0000
R-squared	0.858305	Mean dependent var	1.609184	
Adjusted R-squared	0.855322	S.D. dependent var	2.360745	
S.E. of regression	0.897947	Akaike info criterion	2.652722	
Sum squared resid	76.59931	Schwarz criterion	2.731854	
Log likelihood	-126.9834	F-statistic	287.7266	
Durbin-Watson stat	1.999308	Prob(F-statistic)	0.000000	
Inverted AR Roots	.72-.49i	.72+.49i		

Príklad: simulované dáta (2)

Získaný model

- je stacionárny:

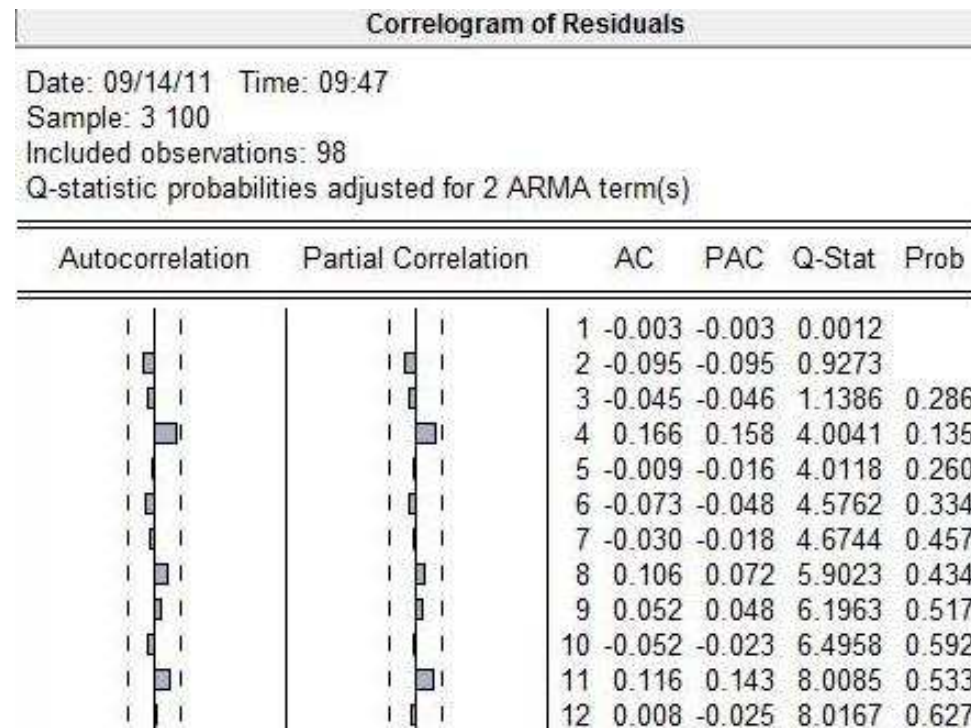
Inverse Roots of AR/MA Polynomial(s)
Specification: X2 C AR(1) AR(2)
Date: 09/14/11 Time: 09:53
Sample: 1 100
Included observations: 98

AR Root(s)	Modulus	Cycle
0.723125 ± 0.491635i	0.874423	10.52298

No root lies outside the unit circle.
ARMA model is stationary.

Príklad: simulované dáta (2)

- má dobré rezíduá:



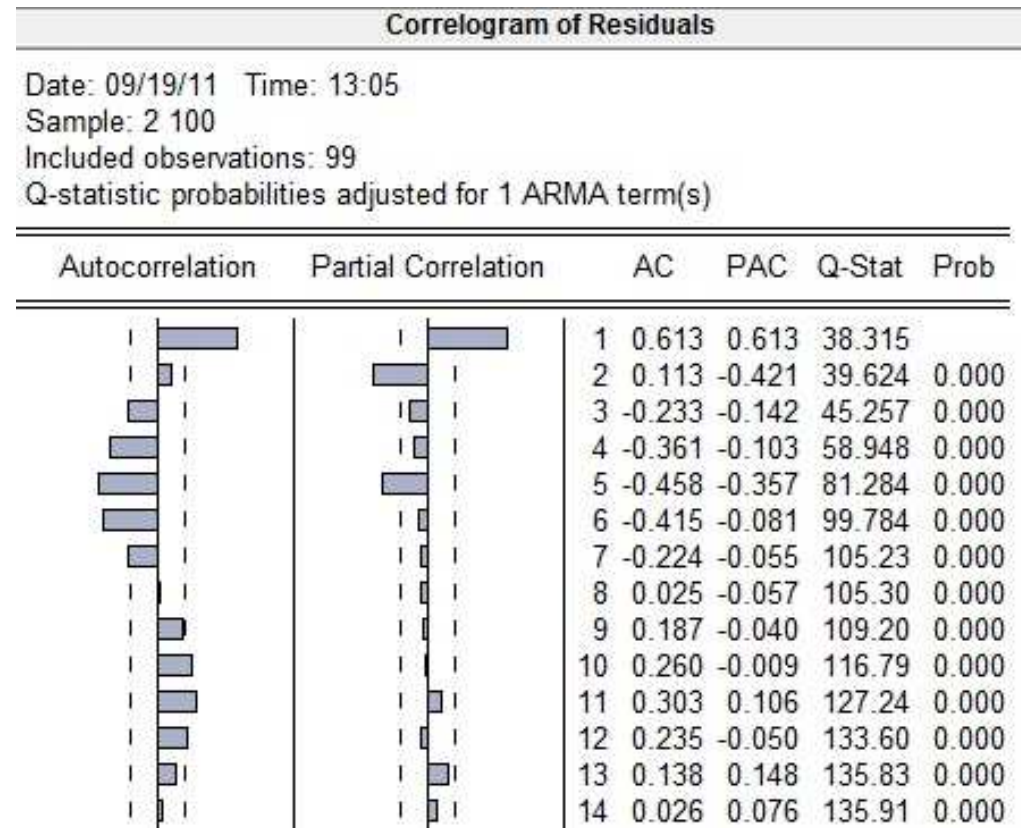
Príklad: simulované dáta (2)

Ak by sme odhadli AR(1), nedostali by sme dobrý model:

Dependent Variable: X2
Method: Least Squares
Date: 09/19/11 Time: 13:05
Sample (adjusted): 2 100
Included observations: 99 after adjustments
Convergence achieved after 3 iterations


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.772761	0.812831	2.180970	0.0316
AR(1)	0.832918	0.058714	14.18595	0.0000
R-squared	0.674760	Mean dependent var	1.615152	
Adjusted R-squared	0.671407	S.D. dependent var	2.349420	
S.E. of regression	1.346759	Akaike info criterion	3.453274	
Sum squared resid	175.9347	Schwarz criterion	3.505701	
Log likelihood	-168.9371	F-statistic	201.2411	
Durbin-Watson stat	0.768890	Prob(F-statistic)	0.000000	
Inverted AR Roots	.83			

Príklad: simulované dáta (2)



- rezíduá nie sú biely šum

Príklad: simulované dáta (3)



→ dáta vyzerajú na AR(4) proces

Príklad: simulované dáta (3)

Odhadneme AR(4) model:

Dependent Variable: X3
Method: Least Squares
Date: 09/14/11 Time: 11:00
Sample (adjusted): 5 150
Included observations: 146 after adjustments
Convergence achieved after 4 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.291702	0.164894	1.769026	0.0791
AR(1)	-0.446956	0.037374	-11.95901	0.0000
AR(2)	-0.142364	0.047729	-2.982727	0.0034
AR(3)	0.230836	0.047962	4.812920	0.0000
AR(4)	0.883163	0.037110	23.79828	0.0000
R-squared	0.964819	Mean dependent var		0.386781
Adjusted R-squared	0.963821	S.D. dependent var		4.926549
S.E. of regression	0.937062	Akaike info criterion		2.741512
Sum squared resid	123.8100	Schwarz criterion		2.843690
Log likelihood	-195.1304	F-statistic		966.7250
Durbin-Watson stat	1.788300	Prob(F-statistic)		0.000000
Inverted AR Roots	.90	-.18-.98i	-.18+.98i	-.99

Príklad: simulované dáta (3)

Získaný model

- je stacionárny:

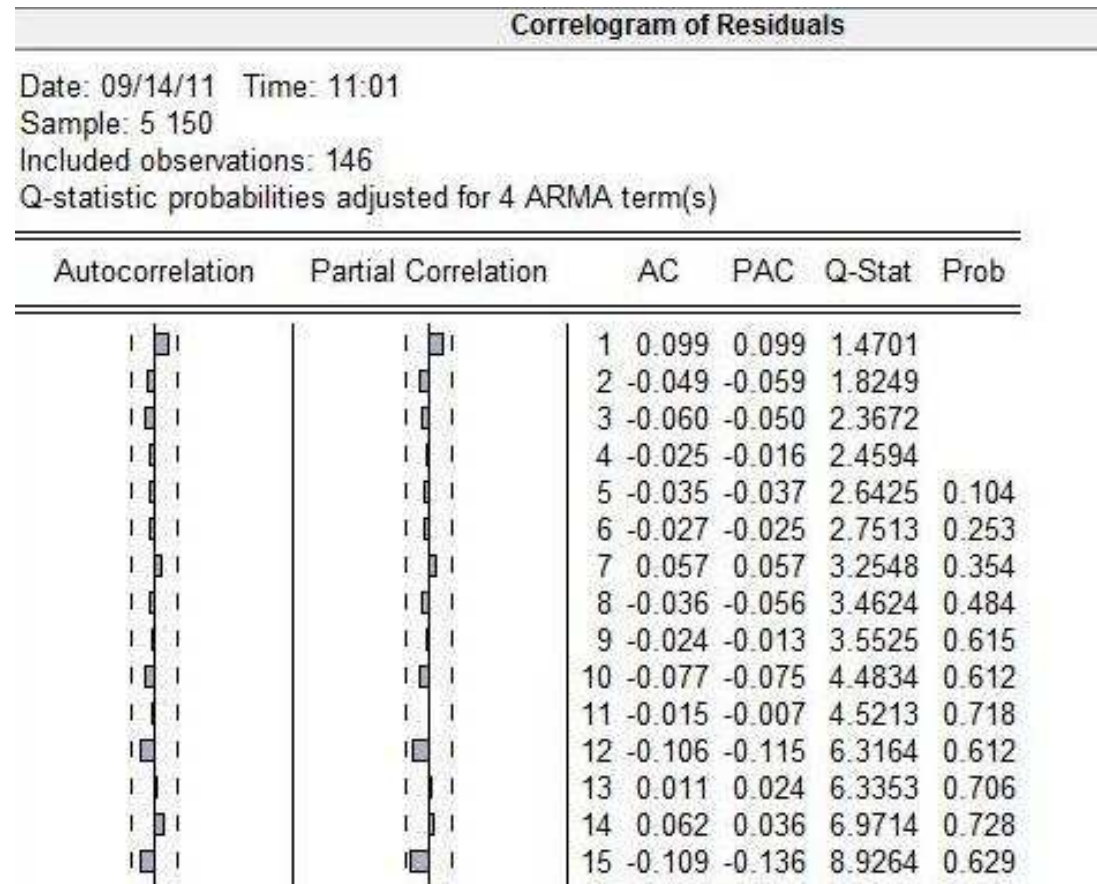
```
Inverse Roots of AR/MA Polynomial(s)  
Specification: X3 C AR(1) AR(2) AR(3) AR(4)  
Date: 09/14/11 Time: 11:02  
Sample: 1 150  
Included observations: 146
```

AR Root(s)	Modulus	Cycle
-0.179619 ± 0.982122i	0.998412	3.586936
-0.986142	0.986142	
0.898425	0.898425	


No root lies outside the unit circle.
ARMA model is stationary.

Príklad: simulované dáta (3)

- má dobré rezíduá:



Príklad: simulované dáta (4)



→ nebude to AR proces

Nabudúce: procesy s takouto ACF a PACF

Príklad: reálne dáta

- Z predchádzajúcich príkladov s reálnymi dátami:
 - ◇ volebné preferencie (vľavo) - AR(1)
 - ◇ úrokové miery (vpravo) - AR(2)

