

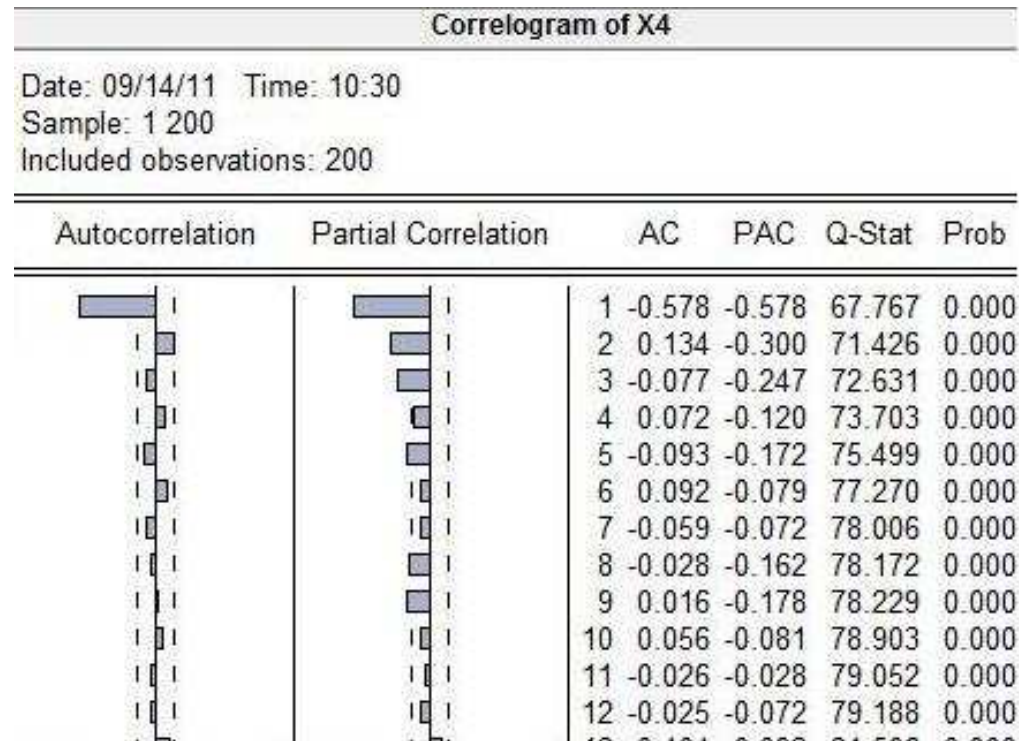
ARMA modely
část 2: moving average modely (MA)

Beáta Stehlíková
Časové rady, FMFI UK, 2011/2012

V.

Moving average proces prvního rádu - MA(1)

Simulované dáta z predchádzajúcej kap.



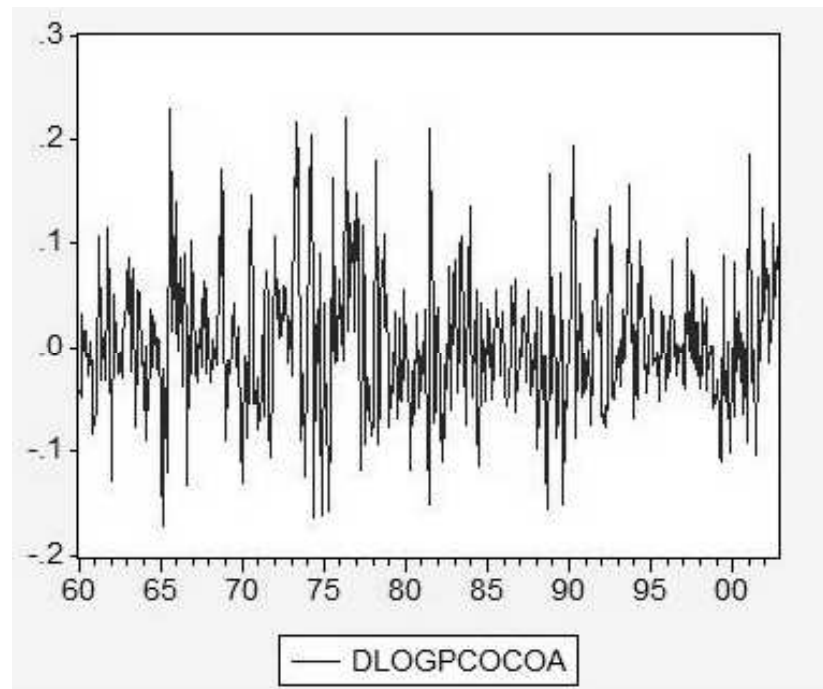
- AR(p) proces - ACF rýchlo klesá (monotónne alebo oscilujúco), PACF sa po p hodnotách rovná nule
- tu je to v podstate naopak → **nebude to AR proces**

Reálne dáta s podobnou ACF

Ben Vogelvang: **Econometrics. Theory and Applications with EViews.** Pearson Education Limited, 2005.


Chapter 14.7. - The Box-Jenkins Approach in Practice

- Mesačné dáta, január 1960 - september 2002
- $pcocoa_t$ - cena kakaa, zlogaritmujeme a kvôli stacionarite budeme pracovať s diferenciami



Reálne dáta - pokračovanie

- Odhadnutá ACF:



- Logaritmy - ACF klesá veľmi pomaly → typické pre dáta, ktoré treba zdiferencovať (presnejšie neskôr)
- Diferencie logaritmov - jedna výrazne nenulová autokorelácia, ostatné skoro nulové

Príklad z prvej prednášky

- Nech u_t je biely šum, definujeme

$$x_t = u_t + u_{t-1}$$

- Vypočítali sme:

$$E[x_t] = 0, \quad Var[x_t] = 2\sigma^2$$

$$Cov[x_t, x_{t+\tau}] = \begin{cases} \sigma^2 & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

$$Cor[x_t, x_{t+\tau}] = \begin{cases} 1/2 & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

- ACF je nulová pre $\tau = 2, 3, \dots$ - presne tá vlastnosť, ktorú potrebujeme

Zovšeobecnenie - MA(1) proces

- Nech u_t je biely šum, potom

$$x_t = \mu + u_t - \beta u_{t-1}$$

sa nazýva **moving average proces prvého rádu - MA(1)**

- **Woldova reprezentácia:** $x_t = \mu + \sum_{j=0}^{\infty} \psi_j u_{t-j}$
MA(1) proces: $\psi_0 = 1, \psi_1 = -\beta, \psi_j = 0$ pre $j = 2, 3, \dots$
- **Momenty a ACF:**

$$E[x_t] = \mu, \quad Var[x_t] = (1 + \beta^2)\sigma^2$$

$$Cov[x_t, x_{t+\tau}] = \begin{cases} -\beta\sigma^2 & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

$$Cor[x_t, x_{t+\tau}] = \begin{cases} -\frac{\beta}{1+\beta^2} & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

MA(1) proces - príklady

1. Nech u_t je biely šum s rozdelením $N(0, 4)$, definujme

$$x_t = u_t + \frac{1}{2}u_{t-1}$$

Potom: $E[x_t] = 0$, $Var[x_t] = (1 + (1/2)^2) \times 4 = 5$

$$Cor[x_t, x_{t+\tau}] = \begin{cases} \frac{1/2}{1+1/4} = 2/5 & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

2. Nech u_t je biely šum s rozdelením $N(0, 1)$, definujme

$$y_t = u_t + 2u_{t-1}$$

Potom: $E[y_t] = 0$, $Var[y_t] = (1 + 4) \times 1 = 5$

$$Cor[y_t, y_{t+\tau}] = \begin{cases} \frac{2}{1+4} = 2/5 & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

Procesy x_t a y_t majú rovnakú ACF \rightarrow nedajú sa rozlíšiť


MA(1) proces - zovšeobecnenie príkladu

- Majme MA(1) proces, t.j. ACF tvaru

$$\text{Cor}[x_t, x_{t+\tau}] = \begin{cases} -\frac{\beta}{1+\beta^2} & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$


- Predpokladajme teraz, že máme danú hodnotu $\rho_1 = \rho(1)$ a chceme z nej spätne určiť koeficient β , t.j.

$$\rho_1 = -\frac{\beta}{1+\beta^2} \Rightarrow \beta = ?$$



MA(1) proces - zovšeobecnenie príkladu

- Máme teda rovnicu: $\rho_1 = -\frac{\beta}{1+\beta^2} \Rightarrow \beta^2 + \frac{1}{\rho_1}\beta + 1 = 0$



→ dve riešenia β_1, β_2 , spĺňajú $\beta_1\beta_2 = 1$.

- Procesy

$$x_t = \mu + u_t - \beta u_{t-1}, \quad x_t = \mu + u_t - \frac{1}{\beta} u_{t-1}$$

majú rovnakú ACF

- Ak chceme jednoznačnú parametrizáciu, potrebujeme dodať ďalšiu podmienku.

Invertovatelnost procesu

- Budeme sa snažit' zapísať proces v tvare AR(∞):

$$x_t = \hat{\mu} + u_t + \psi_1 x_{t-1} + \psi_2 x_{t-2} + \psi_3 x_{t-3} + \dots$$

- ak sa to dá spraviť, proces sa nazýva invertovateľný

- Pre MA(1) proces:

$$\begin{aligned}x_t &= \mu + (1 - \beta L)u_t \\(1 - \beta L)^{-1}x_t &= (1 - \beta L)^{-1}\mu + u_t\end{aligned}$$

$(1 - \beta L)^{-1}$ existuje pre $|\beta| < 1$, vtedy

$$(1 + \beta L + \beta^2 L^2 + \dots)x_t = \mu/(1 - \beta) + u_t$$

$$x_t + \beta x_{t-1} + \beta^2 x_{t-2} + \dots = \mu/(1 - \beta) + u_t$$

MA(1) - invertovateľnosť procesu

- Dostali sme teda **podmienku invertovateľnosti MA(1) procesu**: $|\beta| < 1$
- Iný zápis tejto podmienky:
 - ◇ máme proces $x_t = \mu + (1 - \beta L)u_t$
 - ◇ koreň polynómu $1 - \beta L$ je $1/\beta$
 - ◇ podmienka invertovateľnosti teda hovorí, že koreň $1 - \beta L = 0$ musí byť v absolútnej hodnote väčší ako 1, teda **mimo jednotkového kruhu**

MA(1) - výpočet PACF

- Pripomeňme si všeobecný vzorec;

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

- Pre MA(1) proces je $\rho(k) = 0$ pre $k = 2, 3, \dots$

MA(1) - výpočet PACF

- PACF sa (na rozdiel od AR procesu) nevynuluje:

$$\Phi_{11} = \rho(1)$$

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

$$\Phi_{33} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \rho(1) \\ \rho(1) & 1 & \rho(2) \\ \rho(2) & \rho(1) & \rho(3) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & \rho(2) \\ \rho(1) & 1 & \rho(1) \\ \rho(2) & \rho(1) & 1 \end{pmatrix}} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \rho(1) \\ \rho(1) & 1 & 0 \\ 0 & \rho(1) & 0 \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & 0 \\ \rho(1) & 1 & \rho(1) \\ 0 & \rho(1) & 1 \end{pmatrix}} = \frac{\rho(1)^3}{1 - 2\rho(1)^2}$$

$$\Phi_4 = \frac{-\rho(1)^4}{(1 - \rho(1)^2)^2 - \rho(1)^2}$$

...

MA(1) - výpočet PACF - příklad

- Pre proces $x_t = u_t + \frac{1}{2}u_{t-1}$ sme vypočítali:

$$\rho(1) = 2/5, \quad \rho(k) = 0 \quad (k = 2, 3, \dots)$$

- Počítajme teraz PACF:

$$\Phi_{11} = \rho(1) = 2/5$$

$$\Phi_{22} = \frac{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & \rho(2) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & 1 \end{pmatrix}} = \frac{\det \begin{pmatrix} 1 & 2/5 \\ 2/5 & 0 \end{pmatrix}}{\det \begin{pmatrix} 1 & 2/5 \\ 2/5 & 1 \end{pmatrix}} = \frac{-4/25}{21/25} = -4/21$$

$$\Phi_{33} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \rho(1) \\ \rho(1) & 1 & \rho(2) \\ \rho(2) & \rho(1) & \rho(3) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & \rho(2) \\ \rho(1) & 1 & \rho(1) \\ \rho(2) & \rho(1) & 1 \end{pmatrix}} = \frac{\det \begin{pmatrix} 1 & 2/5 & 2/5 \\ 2/5 & 1 & 0 \\ 0 & 2/5 & 0 \end{pmatrix}}{\det \begin{pmatrix} 1 & 2/5 & 0 \\ 2/5 & 1 & 2/5 \\ 0 & 2/5 & 1 \end{pmatrix}} = \frac{8/125}{17/25} = 8/85$$


...

MA(1) - výpočet PACF - příklad

- Viac členov PACF v softvéri R:

```
R Console
> ARMAacf(ma=0.5, lag.max=10, pacf=TRUE)
[1] 0.4000000000 -0.190476190 0.094117647 -0.046920821 0.023443223
[6] -0.011719465 0.005859464 -0.002929699 0.001464845 -0.000732422
```

Vo forme grafu:



- Zopakujme si - pre MA(2) proces:
 - ◇ ACF: od druhej hodnoty nulová
 - ◇ PACF: nevynuluje sa

Reálne dáta - ceny kakaa

- Dáta zo začiatku prednášky
- MA(1) model pre diferencie logaritmov cien:

Dependent Variable: D(LOG(PCOCOA))
Method: Least Squares
Date: 08/14/09 Time: 14:51
Sample (adjusted): 1960M02 2002M09
Included observations: 512 after adjustments
Convergence achieved after 6 iterations
MA Backcast: 1960M01

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.002454	0.003738	0.656614	0.5117
MA(1)	0.352651	0.041550	8.487292	0.0000
R-squared	0.112273	Mean dependent var		0.002398
Adjusted R-squared	0.110532	S.D. dependent var		0.066320
S.E. of regression	0.062548	Akaike info criterion		-2.701880
Sum squared resid	1.995221	Schwarz criterion		-2.685324
Log likelihood	693.6813	Hannan-Quinn criter.		-2.695390
F-statistic	64.50096	Durbin-Watson stat		1.987519
Prob(F-statistic)	0.000000			
Inverted MA Roots	-.35			

Reálne dáta - ceny kakaa

- Invertovateľnosť:

MA Root(s)	Modulus	Cycle
-0.352651	0.352651	

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

- ACF rezíduí:

Correlogram of Residuals					
Sample: 1960M02 2002M09					
Included observations: 512					
Q-statistic probabilities adjusted for 1 ARMA term(s)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.003	0.003	0.0055	
		2 -0.008	-0.008	0.0371	0.847
		3 -0.014	-0.014	0.1382	0.933
		4 0.032	0.032	0.6730	0.880
		5 -0.057	-0.057	2.3587	0.670
		6 0.037	0.038	3.0731	0.689
		7 -0.062	-0.063	5.0529	0.537
		8 0.026	0.025	5.3941	0.612
		9 0.034	0.037	6.0032	0.647
		10 0.089	0.083	10.181	0.336
		11 -0.004	0.004	10.190	0.424
		12 -0.008	-0.015	10.224	0.510
		13 -0.015	-0.008	10.336	0.586
		14 -0.016	-0.024	10.471	0.655

VI.

Moving average proces q -teho rádu - $MA(q)$

MA(q) proces - definícia a vlastnosti

- Nech u_t je biely šum, potom

$$x_t = \mu + u_t - \beta_1 u_{t-1} - \beta_2 u_{t-2} - \dots - \beta_q u_{t-q}$$

sa nazýva **moving average proces q -teho rádu - MA(q)**

- **Woldova reprezentácia:** $x_t = \mu + \sum_{j=0}^{\infty} \psi_j u_{t-j}$
MA(q) proces: $\psi_0 = 1, \psi_1 = -\beta_1, \dots, \psi_q = -\beta_q, \psi_j = 0$
pre $j > q \rightarrow$ **MA(q) proces je vždy stacionárny**
- **Momenty, ACF, PACF:**

$$E[x_t] = \mu, \quad Var[x_t] = (1 + \beta_1^2 + \dots + \beta_q^2) \sigma^2$$

$$Cov[x_t, x_{t+\tau}] = 0 \quad \text{pre } \tau = q + 1, q + 2, \dots$$

$$\Rightarrow Cor[x_t, x_{t+\tau}] = 0 \quad \text{pre } \tau = q + 1, q + 2, \dots$$

MA(q) proces - definícia a vlastnosti

- Výpočet prvých q autokorelácií (môžeme uvažovať $\mu = 0$):

$$\text{Cov}[x_t, x_{t+\tau}] = E[(u_t - \beta_1 u_{t-1} - \dots - \beta_q u_{t-q}) \times (u_{t+\tau} - \beta_1 u_{t+\tau-1} - \dots - \beta_q u_{t+\tau-q})]$$

$$\begin{aligned} &= E[u_t(u_{t+\tau} - \beta_1 u_{t+\tau-1} - \dots - \beta_q u_{t+\tau-q})] \\ &\quad - \beta_1 E[u_{t-1}(u_{t+\tau} - \beta_1 u_{t+\tau-1} - \dots - \beta_q u_{t+\tau-q})] \\ &\quad \dots \\ &\quad - \beta_q E[u_{t-q}(u_{t+\tau} - \beta_1 u_{t+\tau-1} - \dots - \beta_q u_{t+\tau-q})] \end{aligned}$$

MA(q) proces - definícia a vlastnosti

- Výpočet prvých q autokorelácií - pokračovanie:

$$\tau = 1 \Rightarrow \gamma(1) = (-\beta_1 + \beta_1\beta_2 + \dots + \beta_{q-1}\beta_q)\sigma^2$$

$$\tau = 2 \Rightarrow \gamma(2) = (-\beta_2 + \beta_1\beta_3 + \dots + \beta_{q-2}\beta_q)\sigma^2$$

...

$$\tau = q \Rightarrow \gamma(q) = (-\beta_q)\sigma^2$$

- **PACF** - dosadením vypočítaných autokorelácií do všeobecného vzorca (1)

MA(q) proces - definícia a vlastnosti

- Invertovateľnosť:

$$x_t = \mu + u_t - \beta_1 u_{t-1} - \beta_2 u_{t-2} - \dots - \beta_q u_{t-q}$$

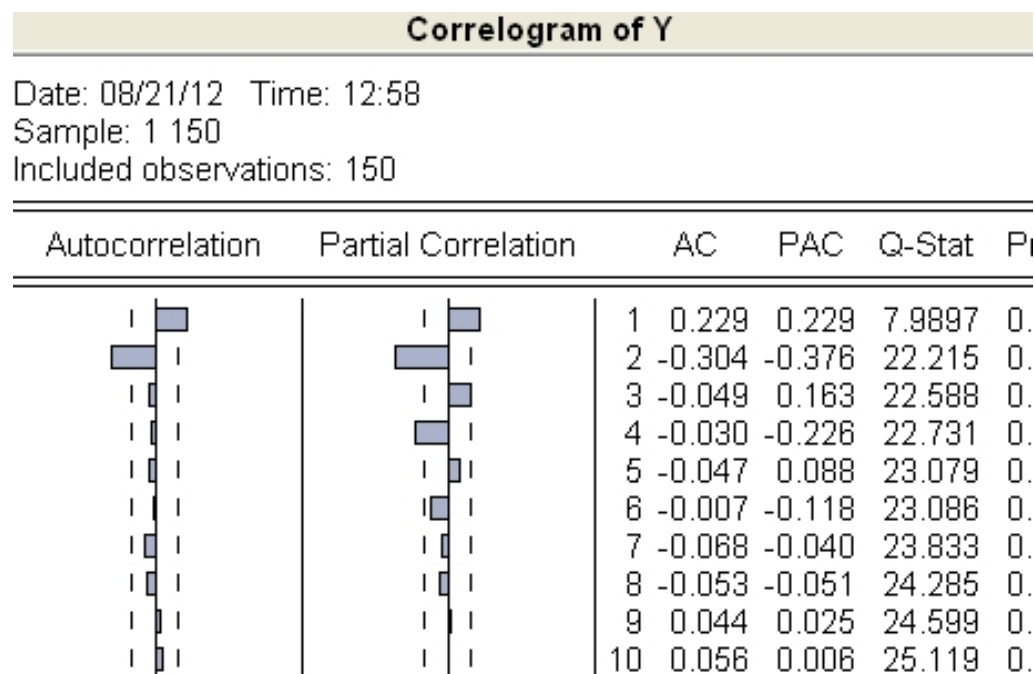
$$x_t = \mu + (1 - \beta_1 L - \dots - \beta_q L^q) u_t$$

- Existencia inverzného operátora

$(1 - \beta_1 L - \dots - \beta_q L^q)^{-1}$ - korene polynómu $1 - \beta_1 L - \dots - \beta_q L^q = 0$ musia byť mimo jednotkového kruhu

Príklad 1: simulované dáta

- Výberová ACF a PACF z dát:



- PACF nie je po nejakom počte členov nulová → nebude to AR proces
- ACF má prvé dve hodnoty výraznejšie, ostatné skoro nulové → skúsime odhadnúť MA(2) proces

Príklad 1: simulované dáta

- Odhadnutý MA(2) proces:













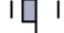









Dependent Variable: Y
Method: Least Squares
Date: 08/21/12 Time: 12:59
Sample: 1 150
Included observations: 150
Convergence achieved after 9 iterations
MA Backcast: -1 0

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.659055	0.024362	27.05261	0.0000
MA(1)	0.457897	0.074472	6.148559	0.0000
MA(2)	-0.432538	0.074795	-5.782960	0.0000
R-squared	0.272208	Mean dependent var		0.658027
Adjusted R-squared	0.262306	S.D. dependent var		0.337583
S.E. of regression	0.289947	Akaike info criterion		0.381560
Sum squared resid	12.35818	Schwarz criterion		0.441772
Log likelihood	-25.61697	Hannan-Quinn criter.		0.406022
F-statistic	27.49037	Durbin-Watson stat		1.979532
Prob(F-statistic)	0.000000			
Inverted MA Roots	.47	-.93		

- Stacionarita - MA proces je vždy stacionárny
- Invertovateľnosť z koreňov - je invertovateľný

Príklad 1: simulované dáta

- ACF rezíduí, Q štatistika - v poriadku:

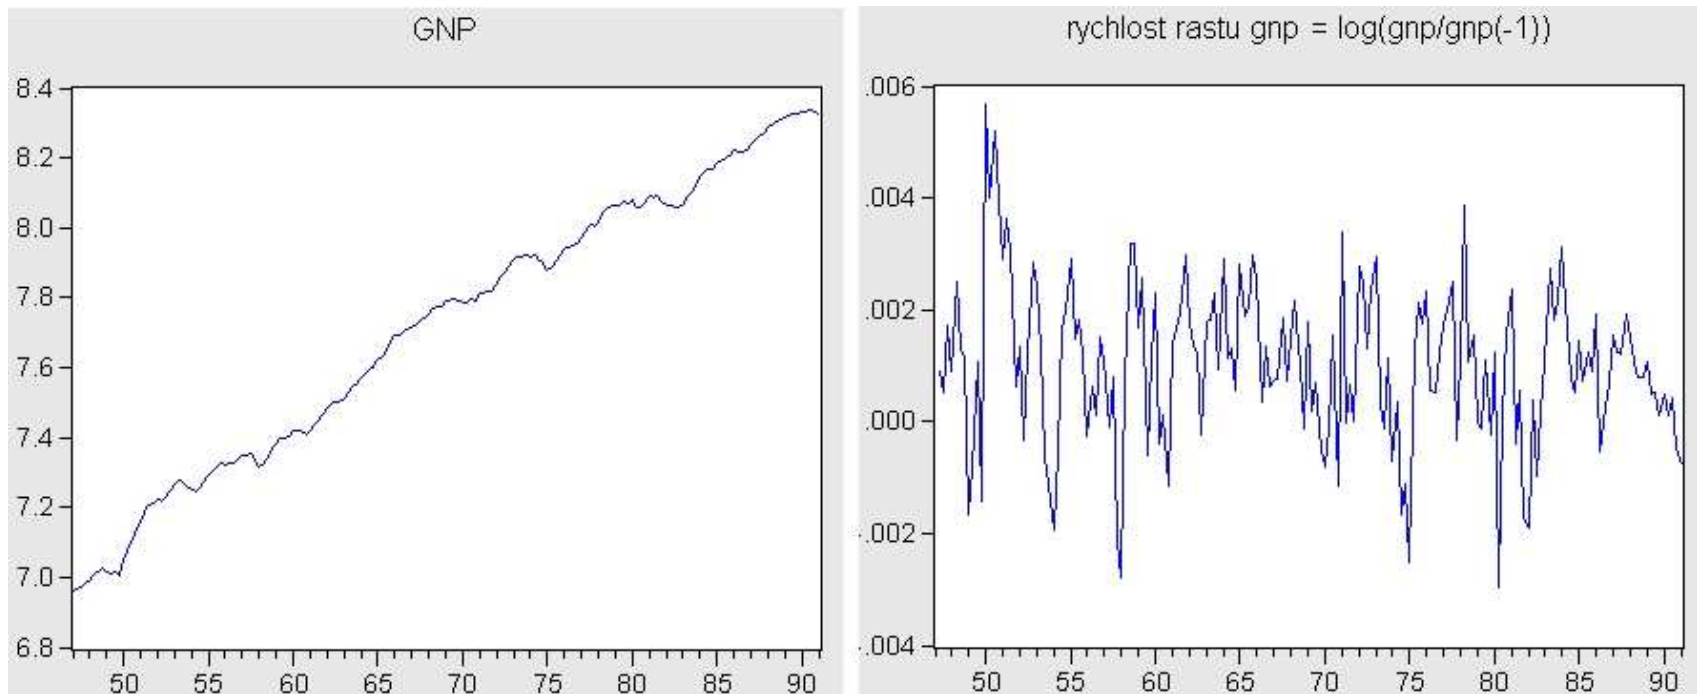
Correlogram of Residuals						
Date: 08/21/12 Time: 12:59						
Sample: 1 150						
Included observations: 150						
Q-statistic probabilities adjusted for 2 ARMA term(s)						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.008	0.008	0.0107	
		2	0.028	0.028	0.1357	
		3	-0.084	-0.085	1.2359	0.266
		4	0.023	0.024	1.3191	0.517
		5	-0.106	-0.103	3.1006	0.376
		6	0.023	0.017	3.1810	0.528
		7	-0.083	-0.076	4.2663	0.512
		8	-0.043	-0.061	4.5646	0.601
		9	0.054	0.068	5.0340	0.656
		10	-0.007	-0.033	5.0420	0.753
		11	0.081	0.082	6.1175	0.728

Príklad 2: rýchlosť rastu HDP

R.H. Shumway, D.S. Stoffer: **Time Series Analysis and Its Applications**. Springer, 2000.

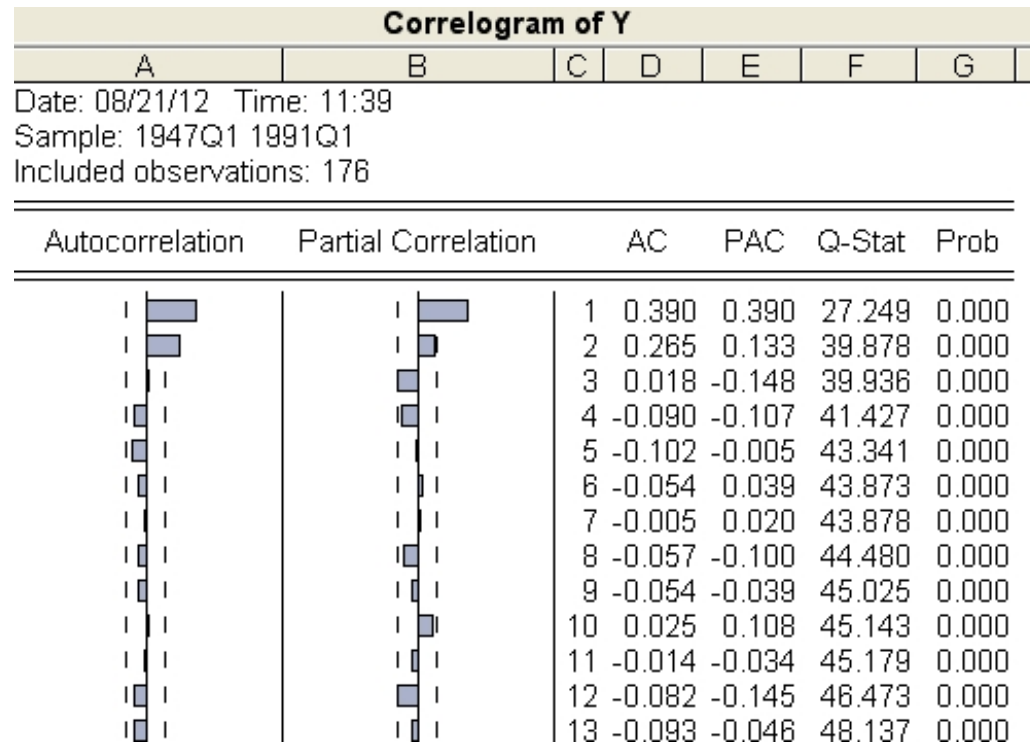
Example 2.32, 2.33

- HNP USA, rýchlosť rastu: $y_t = \ln(gnp_t / gnp_{t-1})$
- Štvrt'ročné dáta, 19747q1-1991q1, sezónne očitstené



Príklad 2: rýchlosť rastu HDP

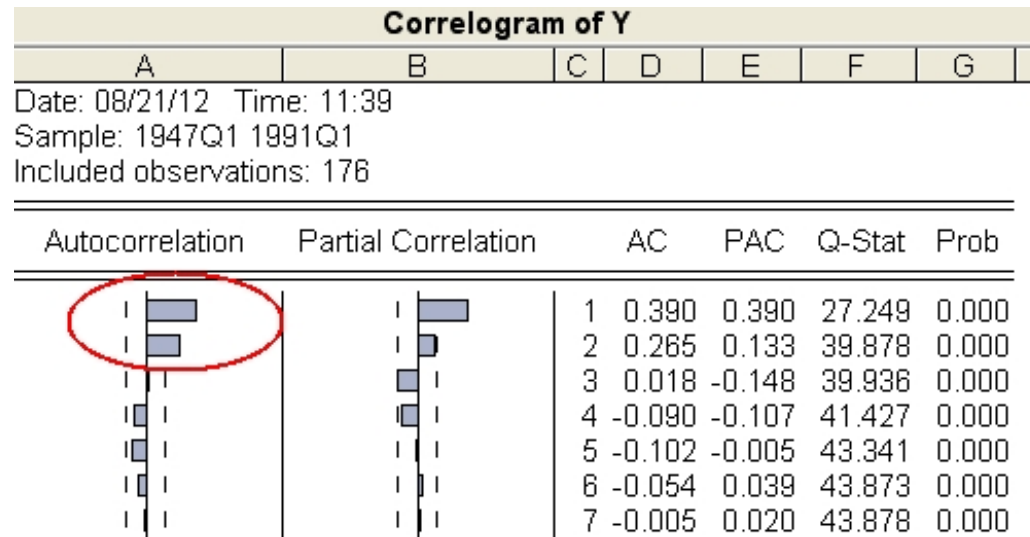
- Výberová ACF a PACF:



- Nie je to také jednoznačné ako v predchádzajúcich príkladoch

Príklad 2: rýchlosť rastu HDP

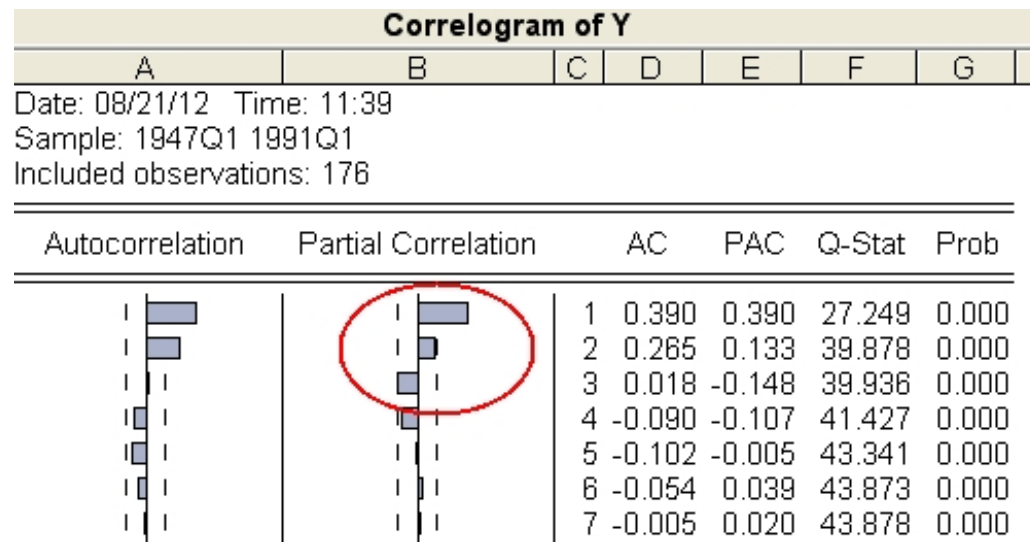
- [Shumway, Stoffer; Example 2.32]:
"Inspecting the sample ACF and PACF we might feel that the ACF is cutting off a lag 2 and the PACF is tailing off"



- To by znamenalo **MA(2)** model

Príklad 2: rýchlosť rastu HDP

- Ale tiež [Shumway, Stoffer; Example 2.32]:
"We will also suggest that it appears that the ACF is tailing off and the PACF is cutting off at lag 3"



- To by znamenalo **AR(3) model**
- Odhadneme oba modely.

Príklad 2: rýchlosť rastu HDP

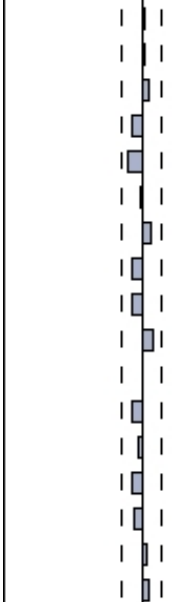

- MA(2) model - výstup:

Dependent Variable: Y
Method: Least Squares
Date: 08/21/12 Time: 11:40
Sample (adjusted): 1947Q2 1991Q1
Included observations: 176 after adjustments
Convergence achieved after 10 iterations
MA Backcast: 1946Q4 1947Q1

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.001009	0.000157	6.443225	0.0000
MA(1)	0.319143	0.073009	4.371266	0.0000
MA(2)	0.286871	0.073115	3.923554	0.0001
R-squared	0.180811	Mean dependent var		0.001015
Adjusted R-squared	0.171341	S.D. dependent var		0.001424
S.E. of regression	0.001296	Akaike info criterion		-10.44236
Sum squared resid	0.000291	Schwarz criterion		-10.38832
Log likelihood	921.9276	Hannan-Quinn criter.		-10.42044
F-statistic	19.09224	Durbin-Watson stat		1.933744
Prob(F-statistic)	0.000000			
Inverted MA Roots	-.16+.51i	-.16-.51i		

Príklad 2: rýchlosť rastu HDP

- MA(2) model - rezíduá:

Correlogram of Residuals						
A	B	C	D	E	F	G
Date: 08/21/12 Time: 11:40						
Sample: 1947Q2 1991Q1						
Included observations: 176						
Q-statistic probabilities adjusted for 2 ARMA term(s)						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.030	0.030	0.1628	
		2	0.025	0.024	0.2721	
		3	0.059	0.057	0.8977	0.343
		4	-0.079	-0.084	2.0477	0.359
		5	-0.105	-0.104	4.0685	0.254
		6	-0.003	0.003	4.0702	0.397
		7	0.067	0.085	4.9080	0.427
		8	-0.073	-0.073	5.9045	0.434
		9	-0.080	-0.101	7.0924	0.419
		10	0.087	0.080	8.5233	0.384
		11	0.013	0.040	8.5555	0.479
		12	-0.081	-0.081	9.8122	0.457
		13	-0.032	-0.077	10.008	0.530
		14	-0.070	-0.073	10.943	0.534
		15	-0.061	-0.008	11.666	0.555
		16	0.040	0.055	11.973	0.608
		17	0.054	0.011	12.549	0.637

- CVIČENIE: stacionarita, invertovateľnosť, autokorelácia rezíduí → je model vyhovujúci?

Príklad 2: rýchlosť rastu HDP



- AR(3) model - výstup:

Dependent Variable: Y
Method: Least Squares
Date: 08/21/12 Time: 11:41
Sample (adjusted): 1948Q1 1991Q1
Included observations: 173 after adjustments
Convergence achieved after 3 iterations

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.001006	0.000165	6.099658	0.0000
AR(1)	0.362642	0.076142	4.762707	0.0000
AR(2)	0.186458	0.079817	2.336061	0.0207
AR(3)	-0.150362	0.076362	-1.969069	0.0506
R-squared	0.188922	Mean dependent var		0.001015
Adjusted R-squared	0.174524	S.D. dependent var		0.001434
S.E. of regression	0.001303	Akaike info criterion		-10.42509
Sum squared resid	0.000287	Schwarz criterion		-10.35218
Log likelihood	905.7701	Hannan-Quinn criter.		-10.39551
F-statistic	13.12154	Durbin-Watson stat		2.024327
Prob(F-statistic)	0.000000			
Inverted AR Roots	.45+.29i	.45-.29i	-.53	

Príklad 2: rýchlosť rastu HDP

- AR(3) model - rezíduá:

Correlogram of Residuals						
A	B	C	D	E	F	G
Date: 08/21/12 Time: 11:41						
Sample: 1948Q1 1991Q1						
Included observations: 173						
Q-statistic probabilities adjusted for 3 ARMA term(s)						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.015	-0.015	0.0403	
		2	0.009	0.009	0.0556	
		3	0.049	0.050	0.4879	
		4	-0.089	-0.088	1.8968	0.168
		5	-0.050	-0.053	2.3387	0.311
		6	0.001	-0.001	2.3389	0.505
		7	0.066	0.077	3.1285	0.537
		8	-0.062	-0.064	3.8331	0.574
		9	-0.107	-0.123	5.9386	0.430
		10	0.088	0.080	7.3911	0.389
		11	0.016	0.045	7.4368	0.490
		12	-0.076	-0.077	8.5313	0.482
		13	-0.026	-0.072	8.6616	0.564
		14	-0.076	-0.078	9.7699	0.551
		15	-0.057	-0.024	10.395	0.581
		16	0.046	0.055	10.799	0.628
		17	0.047	0.013	11.227	0.668
		18	0.061	0.038	11.951	0.683

- CVIČENIE: stacionarita, invertovateľnosť, autokorelácia rezíduí → je model vyhovujúci?

Príklad 2: rýchlosť rastu HDP

- Otázky k odhadnutým modelom:
 1. *Ako môžeme mať pre dáta dva rôzne modely - MA(2) a AR(3)?*
Nie sú "až tak rôzne" - čiastočne ukážeme teraz, čiastočne na teoretickom cvičení.
 2. *Nedajú sa AR a MA členy skombinovať?*
Dajú, dostaneme tak ARMA modely → ďalšia téma prednášok.
 3. *Ako si teda vybrať model?*
Týmto sa budeme zaoberať na praktickom cvičení pri počítači.

Príklad 2: rýchlosť rastu HDP


- K otázke "podobnosti získaných AR(3) a MA(2) procesov":
 - ◇ oba procesy sú stacionárne → dajú sa napísať v tvare **Woldovej reprezentácie** $x_t = \mu + \sum_{j=0}^{\infty} \psi_j u_{t-j}$
 - ◇ MA(2) proces v tom tvare už je: $\psi_0 = 1$,
 $\psi_1 = 0.319143$, $\psi_2 = 0.286871$, ostatné $\psi_k = 0$
 - ◇ AR(3) proces sa dá transformovať
- **Nájdenie Woldovej reprezentácie procesu:**
 - ◇ výpočet na teoretickom cvičení
 - ◇ teraz výsledok získaný pomocou R-ka: príkaz **ARMAtoMA** z balíka **stats**

Príklad 2: rýchlosť rastu HDP

- AR(3) model - koeficienty Woldovej reprezentácie:


```
> ARMAtoMA(ar=c(0.362642,0.186458,-0.150362),lag.max=10)
[1] 0.362642000 0.317967220 0.032563771 0.016568946 -0.035729816
[6] -0.014764073 -0.014507523 -0.002641510 -0.001443011 0.001165553
```

- Porovnanie MA(2) a AR(3) modelu:




Príklad 2: rýchlosť rastu HDP

- Predikcie v AR(3) modeli:



Príklad 2: rýchlosť rastu HDP

- Predikcie v MA(2) modeli:



Predikcie v MA modeli

- MA(q) model:

$$x_t = \mu + u_t - \beta_1 u_{t-1} - \beta_2 u_{t-2} - \dots - \beta_q u_{t-q}$$

- Ak by sme predikcie robili tak, že hodnoty bieleho šumu u by sme nahradili nulou, tak predikcie
 - ◇ by nezáviseli od MA koeficientov β_1, β_2, \dots
 - ◇ by boli konštantné
- Z predchádzajúceho obrázku \rightarrow takto sa to nerobí
- Ako teda: už realizované hodnoty u nenahradíme nulou, ale ich odhadneme z pozorovaných dát x

Predikcie - všeobecne

- Sme v čase t , chceme **predikciu** hodnoty $x_{t+\tau}$, t. j. hodnotu procesu o τ období.
- Označme túto predikciu $\hat{x}_t(\tau)$, teda
 - ◇ index t označuje čas, v ktorom konštruujeme predikciu
 - ◇ argument τ označuje, na koľko období dopredu tá predikcia je
- Predikciou bude **očakávaná hodnota procesu** v tom čase, pri danej informácii, ktorú máme k dispozícii:

$$\hat{x}_t(\tau) = E_t[x_{t+\tau}]$$

(index t vo výraze E_t znamená, že strednú hodnotu počítame v čase t)

Predikcie pre AR proces

- AR proces: takto počítané predikcie sa zhodujú s intuíciou.
- Majme AR(p) proces

$$x_t = \delta + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t.$$

Potom:

$$\begin{aligned} x_{t+\tau} &= \delta + \alpha_1 x_{t+\tau-1} + \dots + \alpha_p x_{t+\tau-p} + u_{t+\tau}, \\ \underbrace{E_t[x_{t+\tau}]}_{\hat{x}_t(\tau)} &= \delta + \alpha_1 E_t[x_{t+\tau-1}] + \dots + \alpha_p E_t[x_{t+\tau-p}] \end{aligned}$$

$$+ \underbrace{E_t[u_{t+\tau}]}_0$$

pričom

$$E_t[x_{t+s}] = \begin{cases} \hat{x}_t(s) & \text{pre } s > 0 \\ x_{t+s} & \text{pre } s \leq 0 \end{cases}$$

Predikcie pre MA proces

- Majme MA(1) proces

$$x_t = \mu + u_t - \beta u_{t-1}$$

a počítajme predikcie $\hat{x}_t(\tau)$:

$$\begin{aligned} x_{t+s} &= \mu + u_{t+s} - \beta u_{t+s-1}, \\ \underbrace{E_t[x_{t+s}]}_{\hat{x}_t(s)} &= \mu + \underbrace{E_t[u_{t+s}]}_0 - \beta \underbrace{E_t[u_{t+s-1}]}_{u_t \text{ pre } s=1, \text{ inak } 0} \end{aligned}$$

Teda:

$$\hat{x}_t(s) = \begin{cases} \mu - \beta u_t & \text{pre } s = 1 \\ \mu & \text{pre } s = 2, 3, \dots \end{cases}$$

- CVIČENIE: Dokážte, že pre MA(q) proces platí $\hat{x}_t(s) = \mu$ pre $s > q$ a že pre $s \leq q$ predikcie obsahujú realizované hodnoty bieleho šumu u

Predikcie pre MA proces

- Predikcie pre MA(1) proces $x_t = \mu + u_t - \beta u_{t-1}$ sú

$$\hat{x}_t(s) = \begin{cases} \mu - \beta u_t & \text{pre } s = 1 \\ \mu & \text{pre } s = 2, 3, \dots \end{cases}$$

- obsahujú hodnotu bieleho šumu u_t . Táto hodnota už bola v čase konštrukcie predikcií realizovaná, **nie sme však schopní ju pozorovať**.

- Cvičenie z predch. slajdu \Rightarrow podobná situácia nastáva pre ľubovoľný MA(q) proces
- **Ako prakticky počítat' predikcie?**
Myšlienka: **vyjadríme u_t pomocou hodnôt procesu x**
- Tento výpočet si ukážeme na MA(1) procese

Predikcie pre MA(1) proces

- Vyjadrujeme teda u_t pomocou x_1, x_2, \dots, x_t
- Využijeme pritom:

- ◇ Pre MA(1) sme odvodili

$$(2) \quad \hat{x}_t(1) = \mu - \beta u_t$$

- ◇ Pre predikčnú chybu platí

$$(3) \quad x_t - \hat{x}_{t-1}(1) = u_t$$

- Budeme postupne počítat' $\hat{x}_t(1)$ pre $t = 0, 1, 2, \dots$

$$(4) \quad \hat{x}_0(1) \stackrel{(2)}{=} \mu - \beta u_0$$

Predikcie pre MA(1) proces

- Pre $t = 1$:

$$\hat{x}_1(1) \stackrel{(2)}{=} \mu - \beta u_1$$

$$\stackrel{(3)}{=} \mu - \beta[x_1 - \hat{x}_0(1)]$$

$$\stackrel{(4)}{=} \mu - \beta[x_1 - (\mu - \beta u_0)]$$

$$(5) \quad = \mu(1 + \beta) - \beta x_1 - \beta^2 u_0$$

- Pre $t = 2$:

$$\hat{x}_2(1) \stackrel{(2)}{=} \mu - \beta u_2$$

$$\stackrel{(3)}{=} \mu - \beta[x_2 - \hat{x}_1(1)]$$

$$\stackrel{(5)}{=} \mu - \beta[x_2 - (\mu(1 + \beta) - \beta x_1 - \beta^2 u_0)]$$

$$(6) \quad = \mu(1 + \beta + \beta^2) - \beta x_2 - \beta^2 x_1 - \beta^3 u_0$$

Predikcie pre MA(1) proces

- Pre všeobecné t :

$$\hat{x}_t(1) = \mu(1 + \beta + \beta^2 + \dots + \beta^t) - \beta x_t - \beta^2 x_{t-1} - \dots - \beta^t x_1 - \beta^{t+1} u_0$$

- Aj tu vystupuje nepozorovateľná hodnota u_0 , ale vplyv člena $\beta^{t+1} u_0$ ide k nule pre $t \rightarrow \infty$ (kde t je počet dát) \Rightarrow môžeme ho zanedbať
- Dostaneme:

$$\hat{x}_t(1) = \mu(1 + \beta + \beta^2 + \dots + \beta^t) - \beta x_t - \beta^2 x_{t-1} - \dots - \beta^t x_1$$

- Ako sme už povedali, $\hat{x}_t(s) = \mu$ pre $s = 2, 3, \dots$