

**SEMINÁRNÍ PRÁCE Z 4ST432**

**Tereza Michlíková (xmict05)**

**ZS 06/07**

## Nesezónní časová řada - Základní údaje o časové řadě

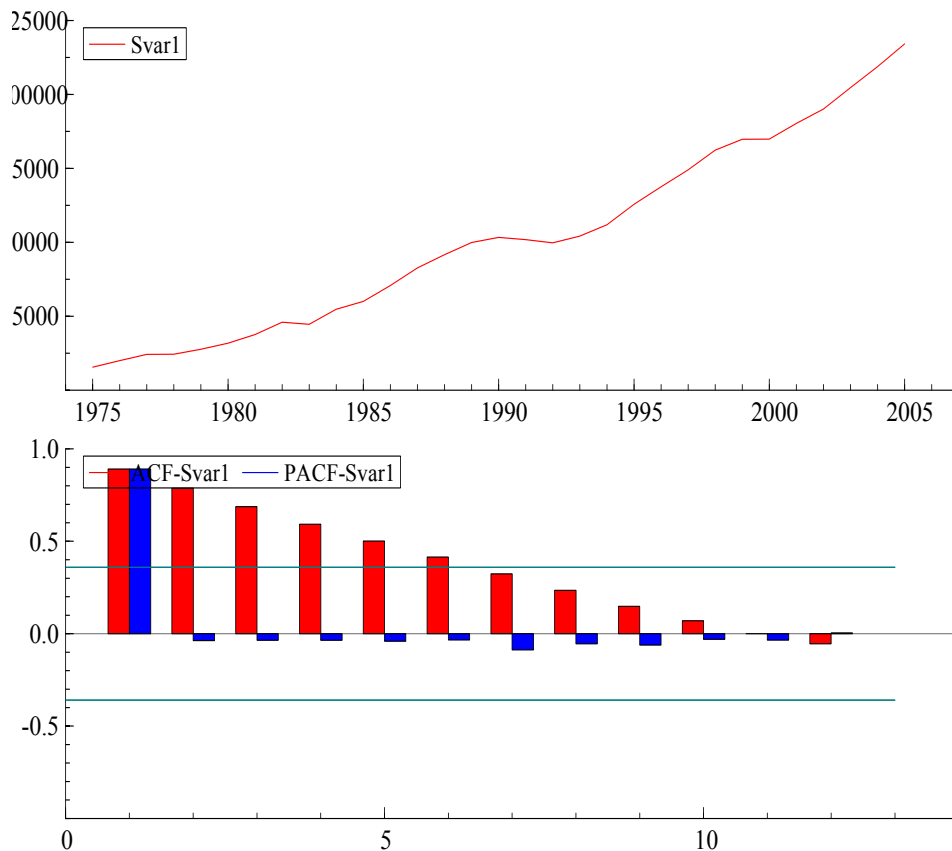
Časová řada příjmy z daní z příjmu v Austrálii ( <http://www.economagic.com/em-cgi/data.exe/tmp/213-220-208-205!20061203093308> ) v milionech AUD.

Jedná se o roční časovou řadu od roku 1975 do roku 2005.

Tabulka 1

rok	Příjmy z DzP	1.diference
1975-1	7770	
1976-1	10019	2249
1977-1	12109	2090
1978-1	12164	55
1979-1	13866	1702
1980-1	15915	2049
1981-1	18859	2944
1982-1	22976	4117
1983-1	22281	-695
1984-1	27384	5103
1985-1	30072	2688
1986-1	35375	5303
1987-1	41312	5937
1988-1	45828	4516
1989-1	49955	4127
1990-1	51654	1699
1991-1	50935	-719
1992-1	49824	-1111
1993-1	52114	2290
1994-1	55936	3822
1995-1	62865	6929
1996-1	68773	5908
1997-1	74523	5750
1998-1	81173	6650
1999-1	84842	3669
2000-1	84887	45
2001-1	90217	5330
2002-1	95103	4886
2003-1	102329	7226
2004-1	109403	7074
2005-1	117057	7654

## Grafická analýza



Z rostoucího průběhu a z grafu autokorelační funkce ( ACF ) a parciální autokorelační funkce ( PACF ), kde je první hodnota blízká jedné, vyplývá, že se jedná o nestacionární časovou řadu.

## Rozšířený Dickey-Fullerův test

Předpoklad nestacionarity se pokusíme potvrdit pomocí rozšířeného Dickey-Fullerova testu.

Unit-root tests (using prijmy z dani2.xls)  
The sample is 1977 - 2005

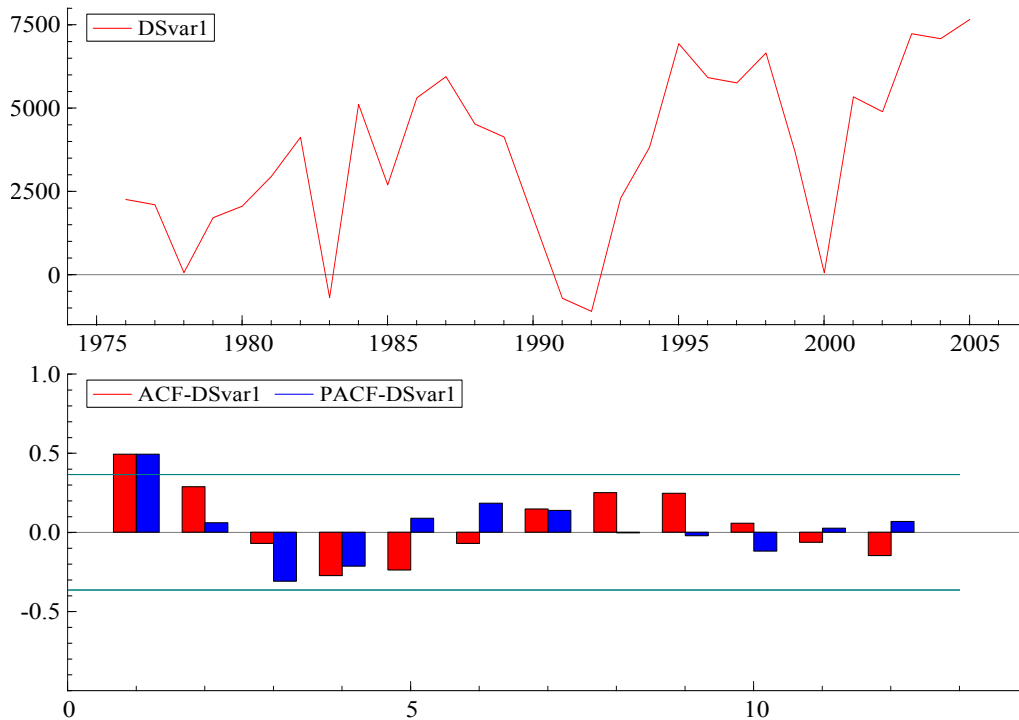
Svar1: ADF tests (T=29, Constant; 5%=-2.97 1%=-3.68)

D-lag	t-adf	beta Y_1	sigma	t-DY_lag	t-prob	AIC	F-prob
1	1.685	1.0269	2180.	1.961	0.0607	15.47	
0	2.958	1.0428	2292.			15.54	0.0607

Jak můžeme vidět hodnota t-prob je u zpoždění 1 rovna 0,0607, což je větší než 0,05. Z toho vyplývá, že 1.zpoždění je v modelu statisticky nevýznamné. Hodnota testového kritéria ADF ( t-adf ) je u zpoždění 0 rovna 2,958, což je větší než -2,97, z toho vyplývá, že na 5ti% hladině významnosti nezamítáme testovanou hypotézu  $H_0$  o nestacionaritě časové řady ( tj. časová řada je nestacionární ). Časovou řadu budeme stacionarizovat pomocí 1.diferencí.

## 1.diference

Výsledky prvních diferencí jsou uvedeny v tabulce 1.



Stacionarizovaná časová řada a její autokorelační a parciální autokorelační funkce je vidět na grafu výše. Podle grafu autokorelační a parciální autokorelační funkce můžeme vidět, že statisticky významné jsou pouze první hodnoty autokorelační a parciální autokorelační funkce. Proto nelze jednoznačně odhadnout, zda se bude vhodnější model ARIMA ( 1,1,0 ) nebo ARIMA (0,1,1).

### Přidání procesu AR(1) do modelu

The estimation sample is: 1976 - 2005

The dependent variable is: DSvar1 (prijmy z dani2.xls)


	Coefficient	Std.Error	t-value	t-prob
AR-1	0.541346	0.1624	3.33	0.003
Constant	3910.97	878.3	4.45	0.000

log-likelihood	-272.590647			
no. of observations	30	no. of parameters	3	
AIC.T	551.181295	AIC	18.3727098	
mean(DSvar1)	3642.9	var(DSvar1)	6.32802e+006	
sigma	2174.09	sigma^2	4.72668e+006	

Podle t-testu vidíme, že jak parametr procesu AR(1), tak konstanta jsou v modelu statisticky významné. Ani jedna hodnota t-prob není větší než 0,05.

## Diagnostika odhadnutého modelu ARIMA (1,1,0)



Hodnoty autokorelační a parciální autokorelační funkce leží uvnitř tolerančních mezí, můžeme tedy říci, že rezidua nevykazují autokorelaci. Tuto skutečnost indikuje také Portmanteau test.

### Portmanteau test

Portmanteau statistic for residuals  
Portmanteau(12):  $\text{Chi}^2(11) = 9.1510$  [0.6080]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

### Jarque-Bera test

Normality test for residuals  
Asymptotic test:  $\text{Chi}^2(2) = 0.85892$  [0.6509]  
Normality test:  $\text{Chi}^2(2) = 0.76693$  [0.6815]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka má normální rozdělení.

### Test ARCH (1)

ARCH coefficients:  
Lag Coefficient Std.Error  
1 0.18202 0.1905  
RSS = 8.48312e+014 sigma = 5.71204e+006

Testing for error ARCH from lags 1 to 1  
ARCH 1-1 test:  $F(1,26) = 0.91335$  [0.3480]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka je podmíněně homoskedastická.

Model ARIMA (1,1,0) je vhodný.

## Přidání procesu MA(1) do modelu

The estimation sample is: 1976 - 2005

The dependent variable is: DSvar1 (prijmy z dani2.xls)


	Coefficient	Std.Error	t-value	t-prob
MA-1	0.373622	0.1390	2.69	0.012
Constant	3658.27	612.6	5.97	0.000

log-likelihood	-274.466644			
no. of observations	30	no. of parameters	3	
AIC.T	554.933289	AIC	18.4977763	
mean(DSvar1)	3642.9	var(DSvar1)	6.32802e+006	
sigma	2314.39	sigma^2	5.35639e+006	

Podle t-testu vidíme, že jak parametr procesu MA(1), tak konstanta jsou v modelu statisticky významné. Ani jedna hodnota t-prob není větší než 0,05.

## Diagnostika odhadnutého modelu ARIMA (0,1,1)



Hodnoty autokorelační a parciální autokorelační funkce leží uvnitř tolerančních mezí, můžeme tedy říci, že rezidua nevykazují autokorelaci. Tuto skutečnost indikuje také Portmanteau test.

### Portmanteau test

Portmanteau statistic for residuals

Portmanteau(12):  $\chi^2(11) = 11.271$  [0.4208]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

### Jarque-Bera test

Normality test for residuals

Asymptotic test:  $\chi^2(2) = 1.3588$  [0.5069]

Normality test:  $\chi^2(2) = 1.5406$  [0.4629]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka má normální rozdělení.

## Test ARCH (1)

ARCH coefficients:

Lag	Coefficient	Std.Error
1	-0.008397	0.1981

RSS = 8.25017e+014    sigma = 5.63307e+006

Testing for error ARCH from lags 1 to 1

ARCH 1-1 test:    F(1,26) = 0.0017964 [0.9665]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka je podmíněně homoskedastická.

Model ARIMA (0,1,1) je vhodný.

## Porovnání modelů

Srovnání modelů na základě Akeikeho kritéria volíme model ARIMA (1,1,0), který má nižší hodnotu tohoto kritéria.

## Předpovědi dle modelu ARIMA (1,1,0)

2006	5937.24181228791
2007	5007.88194252219
2008	4504.7768612632
2009	4232.42302824001


Z výstupu dostáváme předpovědi 1.diferencí.

Přepočtem z rovnice 1.diferencí dostáváme tyto hodnoty.

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

2006	122994,24
2007	128002,12
2008	132506,90
2009	136739,32

V následujícím grafu je vidět hodnoty původní časové řady ( červená křivka ) a hodnoty předpovědí ( modrá křivka ).




## Sezónní časová řada – základní údaje o časové řadě

Jedná se o čtvrtletní časovou řadu průměrné mzdy v podnikatelském sektoru ( [www.cszo.cz](http://www.cszo.cz) )za období od 1.čtvrtletí 1998 do 4.čtvrtletí 2005.

I.Q. 1998	10833
II.Q. 1998	12075
III.Q. 1998	11856
IV.Q. 1998	13255
I.Q. 1999	11663
II.Q. 1999	12889
III.Q. 1999	12810
IV.Q.1999	14240
I.Q. 2000	12609
II.Q. 2000	13757
III.Q. 2000	13692
IV.Q. 2000	15410
I.Q. 2001	13776
II.Q. 2001	14979
III.Q. 2001	14859
IV.Q. 2001	16522
I.Q. 2002	14789
II.Q. 2002	15991
III.Q. 2002	15819
IV.Q. 2002	17487
I.Q. 2003	15603
II.Q. 2003	16927
III.Q. 2003	16760
IV.Q. 2003	18529
I.Q. 2004	16960
II.Q. 2004	17891
III.Q. 2004	17937
IV.Q. 2004	19697
I.Q. 2005	17775
II.Q. 2005	18836
III.Q. 2005	18924
IV.Q. 2005	20631



## Grafická analýza



Vývoj časové řady je rostoucí, budeme tedy muset diferencovat. Vzhledem k tomu, že sezónní rozdíly se nezvětšují, není třeba řadu zlogaritmovat. Hodnoty autokorelační funkce schodovitě klesají.

## Diference

Musíme rozhodnout, zda budeme časovou řadu diferencovat sezónně nebo ne.

## Přidání procesu I (d) do modelu

ARIMA Model: (0 1 0)  
Nonseasonal differences: 1

Parameter	Value (fixed)
Variance	0.17212E+07

## Likelihood Statistics

Effective number of observations (nefobs)	31
Number of parameters estimated (np)	1
Log likelihood (L)	-266.5442
AIC	535.0883
AICC (F-corrected-AIC)	535.2263

## Přidání procesu SI (d) do modelu

ARIMA Model: (0 0 0) (0 1 0) 4  
Seasonal differences: 1


Parameter	Value (fixed)
Variance	0.10292E+07

### Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	1
Log likelihood (L)	-233.5504
AIC	469.1009
AICC (F-corrected-AIC)	469.2547

Na základě Akeikého kritéria vybíráme diferenci sezónní a dostáváme model SARIMA (0,0,0) (0,1,0).

## Grafická analýza modelu SARIMA (0,0,0) (0,1,0)



Z grafu autokorelační a parciální autokorelační funkce vidíme, že u obou funkcí přesahuje toleranční mez 1. sloupec. Vzhledem k tomu, že hodnoty autokorelační funkce klesají pomaleji, budeme do modelu přidávat proces AR (1). Vzhledem k tomu, že na základě grafu ACF a PACF nemůžeme přesně rozhodnout, který z modelů je nejlepší dostáváme 4 možné modely přidáním procesu AR (1), AR (1) a konstanty, MA (1) nebo MA (1) a konstanty.

## A.Přidání procesu AR (1)

ARIMA Model: (1 0 0)(0 1 0)4  
Seasonal differences: 1

Parameter	Estimate	Standard Errors
-----		
Nonseasonal AR		
Lag 1	0.9864	0.01978
Variance	0.23001E+05	
-----		

### Likelihood Statistics


Effective number of observations (nefobs)	28
Number of parameters estimated (np)	2
Log likelihood (L)	-182.1426
AIC	368.2851
AICC (F-corrected-AIC)	368.7651

Musíme otestovat statistickou významnost odhadu parametru  $\phi_1$ . Hodnota t-statistiky pro parametr AR (1) je 49,8685541.

t(26,2-sided) = 49.869 [0.0000] \*\*

Podle hodnoty p-value [0,0000] můžeme říci, že parametr je statisticky významný.

## Grafická analýza modelu SARIMA ( 1,0,0 ) ( 0,1,0 )



Z grafu je vidět, že jedna hodnota je stále ještě statisticky významná. Vzhledem k tomu, že se jedná o 4. hodnotu autokorelační funkce mohli bychom do modelu přidat proces SMA (1) nebo MA (1).

## A1.přidání procesu MA (1)

MODEL ESTIMATION/EVALUATION

Estimation converged in 27 ARMA iterations, 87 function evaluations.

ARIMA Model: (1 0 1)(0 1 0)4

Seasonal differences: 1

Parameter	Estimate	Standard Errors
-----		
Nonseasonal AR		
Lag 1	0.9964	0.00702
Nonseasonal MA		
Lag 1	0.4412	0.16339
Variance	0.19347E+05	
-----		

### Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	3
Log likelihood (L)	-179.9077
AIC	365.8154
AICC (F-corrected-AIC)	366.8154

Musíme otestovat statistickou významnost odhadu parametru  $\phi_1$  a  $\theta_1$ . Hodnota t-statistiky pro parametr AR (1) je 141,93732.

t(25,2-sided) = 141.94 [0.0000] \*\*


Podle hodnoty p-value [0,0000] můžeme říci, že parametr je statisticky významný.

Hodnota t-statistiky pro parametr MA (1) je 2,700287655.

t(25,2-sided) = 2.7003 [0.0123] \*

Podle hodnoty p-value [0,0123] můžeme říci, že parametr je statisticky významný.

## Grafická analýza modelu SARIMA ( 1,0,1 ) ( 0,1,0 )



Všechny hodnoty ACF a PACF jsou uvnitř tolerančních mezí, pro kontrolu musíme provést diagnostiku modelu.

## Diagnostika modelu SARIMA ( 1,0,1 ) ( 0,1,0 )

### Portmanteau test

Portmanteau statistic for residuals  
Portmanteau(12):  $\text{Chi}^2(12) = 8.3065$  [0.7607]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

### Jarque-Bera test

Normality test for residuals  
Asymptotic test:  $\text{Chi}^2(2) = 1.8246$  [0.4016]  
Normality test:  $\text{Chi}^2(2) = 6.7168$  [0.0348]\*

Na základě hodnoty testového kritéria ( Asymptotic test ) nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka má normální rozdělení. Normality test dává výsledek opačný.

### Test ARCH (1)

ARCH coefficients:  
Lag Coefficient Std.Error  
1 0.049941 0.1958  
RSS = 3.15025e+010 sigma = 34808.5

Testing for error ARCH from lags 1 to 1  
ARCH 1-1 test:  $F(1,26) = 0.065042$  [0.8007]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka je podmíněně homoskedastická.

Model SARIMA (1,0,1 ) (0,1,0) je vhodný.

## A2.přidání procesu SMA (1)

ARIMA Model: (1 0 0) (0 1 1) 4  
Seasonal differences: 1

Parameter	Estimate	Standard Errors
-----		
Nonseasonal AR		
Lag 1	0.9971	0.00579
Seasonal MA		
Lag 4	0.4588	0.16503
Variance	0.18439E+05	

### Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	3
Log likelihood (L)	-179.6867
AIC	365.3733
AICC (F-corrected-AIC)	366.3733

Musíme otestovat statistickou významnost odhadu parametru  $\phi_1$  a  $\Theta_1$ . Hodnota t-statistiky pro parametr AR (1) je 172,2107081.


t(25,2-sided) = 172.21 [0.0000] \*\*

Podle hodnoty p-value [0,0000] můžeme říci, že parametr je statisticky významný. Hodnota t-statistiky pro parametr SMA (1) je 2,780100588.

t(25,2-sided) = 2.7801 [0.0102] \*

Podle hodnoty p-value [0,0102] můžeme říci, že parametr je statisticky významný.

## Grafická analýza modelu SARIMA (1,0,0) (0,1,1)



Všechny hodnoty ACF a PACF jsou uvnitř tolerančních mezí, pro kontrolu musíme provést diagnostiku modelu.

## Diagnostika modelu SARIMA ( 1,0,0 ) ( 0,1,1 )

### Portmanteau test

Portmanteau statistic for residuals

Portmanteau(12): Chi<sup>2</sup>(12) = 6.7522 [0.8735]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu H<sub>0</sub> o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

### Jarque-Bera test

Normality test for residuals

Asymptotic test: Chi<sup>2</sup>(2) = 1.3237 [0.5159]

Normality test: Chi<sup>2</sup>(2) = 3.3964 [0.1830]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu H<sub>0</sub> o tom, že nesystematická složka má normální rozdělení.

### Test ARCH (1)

ARCH coefficients:

Lag	Coefficient	Std.Error
1	0.18353	0.1928

RSS = 2.0217e+010    sigma = 27885.1

Testing for error ARCH from lags 1 to 1

ARCH 1-1 test: F(1,26) = 0.90607 [0.3499] Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu H<sub>0</sub> o tom, že nesystematická složka je podmíněně homoskedastická.

Model SARIMA (1,0,0 ) (0,1,1) je vhodný.

## B.Přidání procesu AR (1) a konstanty

MODEL ESTIMATION/EVALUATION

Variable	Parameter Estimate	Standard Error	t-value
Constant	1000.0609	37.75638	26.49

ARIMA Model: (1 0 0) (0 1 0) 4

Seasonal differences: 1

Parameter	Estimate	Standard Errors
Nonseasonal AR		
Lag 1	0.3809	0.17406
Variance	0.15969E+05	

Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	3
Log likelihood (L)	-175.3067
AIC	356.6135
AICC (F-corrected-AIC)	357.6135

Musíme otestovat statistickou významnost odhadu parametru  $\phi_1$  a konstanty.

Hodnota t-statistiky pro parametr AR (1) je 2,188325865.

$t(25, 2\text{-sided}) = 2.1883 [0.0382] *$


Podle hodnoty p-value [0,0382] můžeme říci, že parametr je statisticky významný.

Hodnota t-statistiky konstanty je 26,49.

$t(25, 2\text{-sided}) = 26.49 [0.0000] **$

Podle hodnoty p-value [0,0000] můžeme říci, že konstanta je statisticky významná.

### Grafická analýza modelu SARIMA ( 1,0,0 ) ( 0,1,0 ) s konstantou



Všechny hodnoty ACF a PACF jsou uvnitř tolerančních mezí, pro kontrolu musíme provést diagnostiku modelu.

### Diagnostika modelu SARIMA ( 1,0,0 ) ( 0,1,0 ) s konstantou

#### Portmanteau test

Portmanteau statistic for residuals

Portmanteau(12):  $\text{Chi}^2(12) = 11.148 [0.5163]$

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

#### Jarque-Bera test

Normality test for residuals

Asymptotic test:  $\text{Chi}^2(2) = 1.1881 [0.5521]$

Normality test:  $\text{Chi}^2(2) = 2.3284 [0.3122]$

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka má normální rozdělení.



## Test ARCH (1)

ARCH coefficients:

Lag	Coefficient	Std.Error
1	0.040277	0.1964

RSS = 1.72722e+010    sigma = 25774.3

Testing for error ARCH from lags 1 to 1

ARCH 1-1 test:    F(1,26) = 0.042061 [0.8391]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka je podmíněně homoskedastická.

Model SARIMA (1,0,0) (0,1,0) s konstantou je vhodný.

## C.Přidání procesu MA (1)

ARIMA Model: (0 0 1) (0 1 0) 4

Seasonal differences: 1

Parameter	Estimate	Standard Errors
-----		
Nonseasonal MA		
Lag 1	-0.9998	0.17261
Variance	0.27877E+06	

Likelihood Statistics


Effective number of observations (nefobs)	28
Number of parameters estimated (np)	2
Log likelihood (L)	-216.9456
AIC	437.8912
AICC (F-corrected-AIC)	438.3712

Musíme otestovat statistickou významnost odhadu parametru  $\theta_1$ . Hodnota t-statistiky pro parametr MA (1) je -5,792248421.

t(26,2-sided) = -5.7922 [0.0000] \*\*

Podle hodnoty p-value [0,000] můžeme říci, že parametr je statisticky významný.

## Grafická analýza modelu SARIMA ( 0,0,1 ) ( 0,1,0 )



Všechny hodnoty ACF a PACF jsou uvnitř tolerančních mezí, pro kontrolu musíme provést diagnostiku modelu.

## Diagnostika modelu SARIMA ( 0,0,1 ) ( 0,1,0 )

### Portmanteau test

Portmanteau statistic for residuals

Portmanteau(12):  $\text{Chi}^2(12) = 225.51$  [0.0000]\*\*

Na základě hodnoty testového kritéria zamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

### Jarque-Bera test

Normality test for residuals

Asymptotic test:  $\text{Chi}^2(2) = 0.36411$  [0.8336]

Normality test:  $\text{Chi}^2(2) = 0.0056450$  [0.9972]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka má normální rozdělení.

### Test ARCH (1)

ARCH coefficients:

Lag	Coefficient	Std.Error
1	-0.52216	0.1682

RSS = 4.24826e+011 sigma = 127826

Testing for error ARCH from lags 1 to 1

ARCH 1-1 test:  $F(1,26) = 9.6422$  [0.0046]\*\*

Na základě hodnoty testového kritéria zamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka je podmíněně homoskedastická.

Model SARIMA ( 0,0,1 ) (0,1,0) není vhodný.

## D.Přidání procesu MA (1) a konstanty

MODEL ESTIMATION/EVALUATION  
Regression Model

Variable	Parameter Estimate	Standard Error	t-value
Constant	1002.9664	32.97902	30.41

ARIMA Model: (0 0 1)(0 1 0)4  
Seasonal differences: 1

Parameter	Estimate	Standard Errors
Nonseasonal MA		
Lag 1	-0.3845	0.17484
Variance	0.16202E+05	

### Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	3
Log likelihood (L)	-175.5108
AIC	357.0215
AICC (F-corrected-AIC)	358.0215

Musíme otestovat statistickou významnost odhadu parametru  $\theta_1$  a konstanty.

Hodnota t-statistiky pro parametr MA (1) je -2.199153512.

t(25,2-sided) = -2.1992 [0.0373] \*


Podle hodnoty p-value [0,0373] můžeme říci, že parametr je statisticky významný.

Hodnota t-statistiky pro konstantu je 30,41.

t(25,2-sided) = 30.41 [0.0000] \*\*

Podle hodnoty p-value [0,000] můžeme říci, že konstanta je statisticky významná.

### Grafická analýza modelu SARIMA (0,0,1) (0,1,0) s konstantou



Z grafu je vidět, že jedna hodnota je stále ještě statisticky významná. Vzhledem k tomu, že se jedná o 4. hodnotu parciální autokorelační funkce mohli bychom do modelu přidat proces SAR (1) nebo AR (1).

### D1.přidání procesu AR (1)

MODEL ESTIMATION/EVALUATION

Estimation converged in 7 ARMA iterations, 36 function evaluations.

Regression Model

Variable	Parameter Estimate	Standard Error	t-value
Constant	998.6032	39.79362	25.09

ARIMA Model: (1 0 1)(0 1 0)4  
Seasonal differences: 1

Parameter	Estimate	Standard Errors
Nonseasonal AR Lag 1	0.4902	0.33373
Nonseasonal MA Lag 1	0.1246	0.38120
Variance	0.15918E+05	

Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	4
Log likelihood (L)	-175.2651
AIC	358.5302
AICC (F-corrected-AIC)	360.2693

Musíme otestovat statistickou významnost odhadu parametrů  $\theta_1$  a  $\phi_1$  a konstanty.

Hodnota t-statistiky pro parametr MA (1) je 1,468852066.

$t(24, 2\text{-sided}) = 1.4689 [0.1549]$

Podle hodnoty p-value [0,1549] můžeme říci, že parametr je statisticky nevýznamný.

Přidáním procesu AR (1) do modelu SARIMA (0,0,1)(0,1,0) s konstantou došlo k tomu, že parametr MA (1) je statisticky nevýznamný. Vyloučením tohoto parametru bychom dostali již výše uvedený model SARIMA (1,0,0)(0,1,0).

## D2.přidání procesu SAR (1)

MODEL ESTIMATION/EVALUATION

Estimation converged in 7 ARMA iterations, 36 function evaluations.

Regression Model

Variable	Parameter Estimate	Standard Error	t-value
Constant	1011.6687	23.11066	43.77

ARIMA Model: (0 0 1)(1 1 0)4

Seasonal differences: 1

Parameter	Estimate	Standard Errors
Seasonal AR Lag 4	-0.3772	0.18180
Nonseasonal MA Lag 1	-0.3922	0.17365
Variance	0.13784E+05	

Likelihood Statistics

Effective number of observations (nefobs)	28
Number of parameters estimated (np)	4
Log likelihood (L)	-173.5673
AIC	355.1345
AICC (F-corrected-AIC)	356.8737

Musíme otestovat statistickou významnost odhadu parametrů  $\theta_1$  a  $\Phi_1$  a konstanty.

Hodnota t-statistiky pro parametr MA (1) je -2,258566081.

t(24,2-sided) = -2.2586 [0.0333] \*

Podle hodnoty p-value [0,0333] můžeme říci, že parametr je statisticky významný.

Hodnota t-statistiky pro parametr SAR (1) je -2,074807481.

t(24,2-sided) = -2.0748 [0.0489] \*

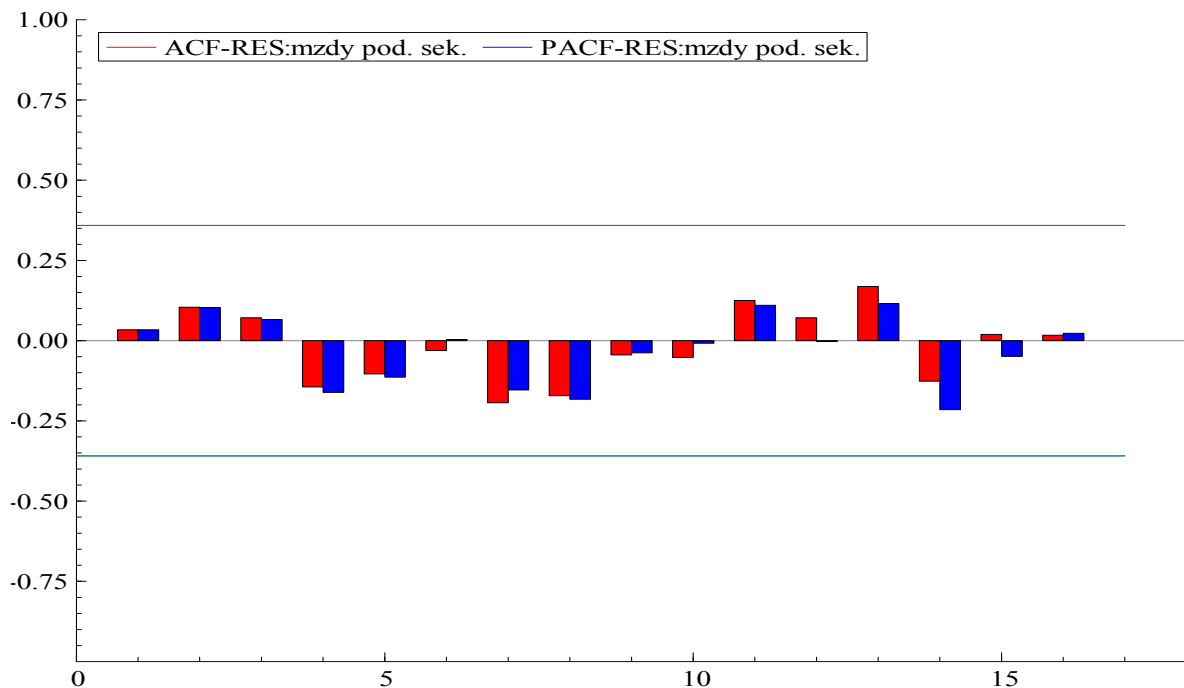
Podle hodnoty p-value [0,0489] můžeme říci, že parametr je statisticky významný.

Hodnota t-statistiky pro konstantu je 43,77.

t(24,2-sided) = 43.77 [0.0000] \*\*

Podle hodnoty p-value [0,0000] můžeme říci, že konstanta je statisticky významná.

## Grafická analýza modelu SARIMA ( 0,0,1 ) ( 1,1,0 ) s konstantou



Všechny hodnoty ACF a PACF jsou uvnitř tolerančních mezí, pro kontrolu musíme provést diagnostiku modelu.

## Diagnostika modelu SARIMA ( 0,0,1 ) ( 1,1,0 ) s konstantou

### Portmanteau test

Portmanteau statistic for residuals

Portmanteau(12):  $\text{Chi}^2(12) = 7.6282$  [0.8135]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka ( rezidua ) jsou neautokorelovaná.

### Jarque-Bera test

Normality test for residuals

Asymptotic test:  $\text{Chi}^2(2) = 0.58886$  [0.7450]

Normality test:  $\text{Chi}^2(2) = 0.40663$  [0.8160]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka má normální rozdělení.

### Test ARCH (1)

ARCH coefficients:

Lag	Coefficient	Std.Error
1	0.061237	0.1975

RSS = 7.04959e+009    sigma = 16466.3

Testing for error ARCH from lags 1 to 1

ARCH 1-1 test:  $F(1,26) = 0.096137$  [0.7590]

Na základě hodnoty testového kritéria nezamítáme testovanou hypotézu  $H_0$  o tom, že nesystematická složka je podmíněně homoskedastická.

Model SARIMA (0,0,1 ) (1,1,0) s konstantou je vhodný.

## Porovnání modelů

Modely SARIMA	AIC	stat. význam. parametrů	graf. analýza	Port-manteau	Jarque-Bera	ARCH(1)	vhodný	postup
(010)(000)	535,0883	xxx	xxx	xxx	xxx	xxx	ne	xxx
(000)(010)	469,1009	xxx	přesahuje 1.sl. ACF 1.sl. PACF	xxx	xxx	xxx	ne	přidáme AR(1) (+konst.) nebo MA(1) (+konst.)
(100)(010)	368,2851	ano	přesahuje 4.sl. ACF	xxx	xxx	xxx	ne	přidáme MA(1) nebo SMA(1)
(101)(010)	365,8154	ano	OK	ano	ano	ano	ano	xxx
(100)(011)	365,3733	ano	OK	ano	ano	ano	ano	xxx
(100)(010)+konst.	356,6135	ano	OK	ano	ano	ano	ano	xxx
(001)(010)	437,8912	ano	OK	ne	ano	ne	ne	xxx
(001)(010)+konst.	357,0215	ano	přesahuje 4.sl. PACF	xxx	xxx	xxx	ne	přidáme AR(1) nebo SAR(1)
(101)(010)+konst.	358,5302	ne	xxx	xxx	xxx	xxx	ne	xxx
(001)(110)+konst.	355,1345	ano	OK	ano	ano	ano	ano	xxx


Ve výše uvedené tabulce je vidět, že nejvhodnějším modelem je podle Akeikého kritéria model SARIMA (001)(110) s konstantou.

$$y_t = c_t + a_t - \theta_1 * a_{t-1} + \Theta_1 y_{t-S} = 1011,6687 + a_t - (-0,3922) * a_{t-1} + (-0,3772) * y_{t-4}$$

## Předpovědi

Date	Forecast	Standard Error
2006.1	18844.99	119.610
2006.2	19872.82	130.066
2006.3	19944.97	130.066
2006.4	21671.97	130.066

V následujícím grafu je vidět hodnoty původní časové řady ( červená křivka ) a hodnoty předpovědí ( modrá křivka ).



### Použitá literatura:

Arlt, J.;Arltová, M.: Ekonomické časové řady; Grada, Praha 2007