

# Jednotkový koreň (unit root), diferencovanie časového radu, ADF test na testovanie jednotkového koreňa

Beáta Stehlíková

2-PMS-102 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

# Obsah

- ▶ Čo je jednotkový koreň, prečo neumožňuje použiť ARMA metodológiu a ako ho odstrániť
- ▶ Ako z dát zistiť, či má proces jednotkový koreň alebo nie → testy jednotkového koreňa (unit root testy)
- ▶ Ako spraviť tento test v R-ku

# Časť 1: Čo je jednotkový koreň, prečo neumožňuje použiť ARMA metodológiu a ako ho odstrániť

## Príklad 1

Majme proces

$$y_t = y_{t-1} + u_t$$

resp. po zápise pomocou operátora posunu

$$(1 - L)y_t = u_t$$

- ▶ je to nestacionárny AR(1) proces
- ▶ polynóm  $1 - L$  má koreň  $L = 1$ , t. j. **jednotkový koreň**
- ▶ keď hovoríme o jednotkovom koreni, ide nám koreň  $L = 1$  autoregresného polynómu - spôsobuje nestacionaritu
- ▶ pre diferencie tohto procesu  $\Delta y_t = y_t - y_{t-1}$  platí  $\Delta y_t = u_t$
- ▶ teda diferencie  $\Delta y_t$  sú stacionárne

## Príklad 2

- ▶ Majme nestacionárny proces s jednotkovým koreňom

$$(1 - \frac{1}{2}L)(1 - L)y_t = 1 + (1 - \frac{1}{3}L)u_t$$

- ▶ Potom pre diferencie tohto procesu

$$\Delta y_t = y_t - y_{t-1} = (1 - L)y_t$$

platí  $(1 - \frac{1}{2}L)\Delta y_t = 1 + (1 - \frac{1}{3}L)u_t$

- ▶ Teda diferencie  $\Delta y_t$  sú stacionárne

## Príklad 3

- ▶ Majme nestacionárny proces s dvojnásobným jednotkovým koreňom

$$(1 - \frac{1}{2}L)(1 - L)^2 y_t = 1 + (1 - \frac{1}{3}L)u_t$$

- ▶ Potom pre druhé diferencie tohto procesu

$$\Delta^2 y_t = \Delta(\Delta y_t) = (1 - L)(1 - L)y_t = (1 - L)^2 y_t$$

platí  $(1 - \frac{1}{2}L)\Delta^2 y_t = 1 + (1 - \frac{1}{3}L)u_t$

- ▶ Teda druhé diferencie  $\Delta y_t$  sú stacionárne

## Vo všeobecnosti

- ▶ Majme proces s jednotkovým koreňom násobnosti  $k$ , pričom ostatné korene sú mimo jednotkového kruhu
- ▶ Potom  $k$ -te diferencie procesu sú stacionárne



## ARIMA modely, terminológia

- ▶ Ak treba proces  $k$  krát diferencovať, aby sme z neho dostali stacionárny proces, nazýva sa integrovaný proces rádu  $k$  a označuje sa  $I(k)$

Canarella, G., Gupta, R., Miller, S. M., & Pollard, S. K. (2019). **Unemployment rate hysteresis and the great recession: exploring the metropolitan evidence**. *Empirical Economics*, 56(1), 61-79.

**Abstract** Standard unit-root tests of the hysteresis hypothesis specify a unit root under the null against the stationary alternative of the natural-rate hypothesis, making the two theories of unemployment mutually exclusive over the sample period. In this paper, we allow switches between hysteresis and natural-rate theory using the Kejriwal, Perron, and Zhou test. The null hypothesis of the test is that the unemployment rate is  $I(1)$  throughout the sample, and the alternative hypothesis is that the unemployment rate changes persistence [i.e., switches between  $I(0)$  and  $I(1)$  regimes]. We apply the test to the unemployment rate of 20 metropolitan statistical areas (MSAs) and the USA. We use monthly observations over the period 1990:1–2016:12 and apply the test to seasonally unadjusted and seasonally adjusted data.

## Časť 2: Ako testovať prítomnosť jednotkového koreňa v dátach - simulácie

## Cieľ


- ▶ Uvažujme najskôr AR(1) proces  $x_t = \delta + \rho x_{t-1} + u_t$
- ▶ Chceme:
  - ▶ testovať hypotézu o jednotkovom koreni (vtedy je proces nestacionárny), teda  $H_0 : \rho = 1$
  - ▶ zistiť, či sa dá zamietnuť v prospech stacionarity, teda  $H_0 : \rho < 1$
- ▶ Skúsme použiť testovanie hypotéz o koeficientoch regresného modelu známe z ekonometrie.
  - ▶ spravíme simulácie
  - ▶ uvidíme, že tento postup bude treba upraviť

## Simulácia 1: klasická regresia a t-štatistika

## Štandardný postup - vieme spraviť:

- ▶ Majme vektor  $x \leftarrow 1:200$
- ▶ Vygenerujeme  $y \leftarrow x + \text{rnorm}(200) * \text{sigma}$
- ▶ Odhadneme model  $y = c + \rho x + \varepsilon$
- ▶ Zaznamenávame:
  - ▶ odhad parametra  $\rho$
  - ▶ hodnotu t-štatistiky zodpovedajúcej hypotéze  $H_0 : \rho = 1$  (ktorá platí)
- ▶ Zopakujeme  $10^5$  krát a vykreslíme histogram

► Ukážka dát:




► Výstup z regresie:

```
summary(lm(y ~ x))$coefficients
```

```
##              Estimate Std. Error    t value      Pr(>|t|)
## (Intercept) 1.0330020 2.01108356  0.5136544 6.080663e-01
## x           0.9884422 0.01735144 56.9660036 9.490913e-12
```


- Odhadnutý koeficient  $\rho$  je 0.98844.
- T-štatistika k hypotéze  $\rho = 1$  sa počíta ako  $\frac{0.98844-1}{0.01735}$

- ▶ Výsledok zo simulácií: odhad parametra  $\rho$  (normálne rozdelenie)





- ▶ Výsledok zo simulácií: t-štatistika (Studentovo rozdelenie, vyznačený 5% kvantil tohto rozdelenia)




## Simulácia 2: jednotkový koreň a t-štatistika


## Druhá simulácia:

- ▶ Majme vektor  $z$  vygenerovaný ako  $z_t = z_{t-1} + \varepsilon_t$
- ▶ Zoberieme  $x \leftarrow z[1:200]$ ,  $y \leftarrow z[2:201]$ , teda  $x_t = z_{t-1}$ ,  
 $y_t = z_t$
- ▶ Odhadneme model  $y = c + \rho x + \varepsilon$ , teda  $z_t = c + \rho z_{t-1} + \varepsilon_t$
- ▶ Zaznamenávame:
  - ▶ odhad parametra  $\rho$
  - ▶ hodnotu t-štatistiky zodpovedajúcej hypotéze  $H_0 : \rho = 1$  (ktorá platí)
- ▶ Zopakujeme  $10^5$  krát a vykreslíme histogram


- Ukážka vygenerovaných dát: proces  $z_t$  do regresie  
 $z_t = c + \rho z_{t-1} + \varepsilon_t$




► Ukážka vygenerovaných dát: dáta do regresie



- ▶ Výsledok zo simulácií: odhad parametra  $\rho$  (nemá normálne rozdelenie)



- ▶ Výsledok zo simulácií: “t-štatistika” (nemá Studentovo rozdelenie, vyznačený 5% kvantil tohto rozdelenia)



## Časť 3: Ako testovať prítomnosť jednotkového koreňa v dátach - ADF test



## Základná myšlienka:

- ▶ Ponecháme výpočet testovacej štatistiky
- ▶ Ale budeme používať **iné kritické hodnoty**
- ▶ Približne aké by mali byť kritické hodnoty (podľa našich simulácií):

```
quantile(t_statistika, 0.05)
```

```
##           5%  
## -2.888873
```

```
quantile(t_statistika, 0.01)
```

```
##           1%  
## -3.471761
```

## Testovanie jednotkového koreňa pre AR(1)

- ▶ AR(1) proces

$$y_t = \rho y_{t-1},$$

jednotkový koreň znamená, že  $\rho = 1$

- ▶ Ekvivalentne:

$$\Delta y_t = (\rho - 1)y_{t-1} + u_t$$

a zaujíma nás **t-štatistika** zo **signifikancie koeficienta pri  $y_{t-1}$** , ale **s inou kritickou hodnotou**

- ▶ Bolo zistené, že tá kritická hodnota
  - ▶ závisí od počtu dát
  - ▶ zmení sa, ak proces obsahuje konštantu a/alebo lineárny trend
- ▶ Vo všeobecnosti:  $\Delta y_t = \alpha + \beta t + (\rho - 1)y_{t-1} + u_t$

## Testovanie jednotkového koreňa pre AR(p)

- ▶ AR(p) proces

$$y_t = \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \alpha_p \dots y_{t-p} + u_t$$

- ▶ Prepíšeme pomocou posunu

$$(1 - \alpha_1 L - \alpha_2 L^2 - \dots - \alpha_p L^p) y_t = u_t$$

- ▶ To, že  $L = 1$  je koreňom, znamená:

$$1 - \alpha_1 1 - \alpha_2 1^2 - \dots - \alpha_p 1^p = 0$$

- ▶ Jednotkový koreň teda predstavuje podmienku

$$\alpha_1 + \dots + \alpha_p = 1$$

- ▶ Máme teda AR(p) proces

$$y_t = \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \alpha_p \dots y_{t-p} + u_t$$

- ▶ Upravíme ho do tvaru

$$y_t = \rho y_{t-1} + \theta_1 \Delta y_{t-1} + \theta_2 \Delta y_{t-2} + \theta_{p-1} \Delta y_{t-p+1} + u_t,$$

kde  $\rho = \sum_{j=1}^p \alpha_j$ ,  $\theta_i = -\sum_{j=i+1}^p \alpha_j$  pre  $i = 1, \dots, p-1$

- ▶ Teda na pravej strane je:

- ▶ predchádzajúca hodnota procesu  $y_{t-1}$  s koeficientom

$$\alpha_1 + \dots + \alpha_p$$

- ▶ diferencie v starších časoch  $\Delta y_{t-1}, \Delta y_{t-2}, \dots, \Delta y_{t-p+1}$

► Napríklad pre AR(3):

$$\begin{aligned}
 y_t &= \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \alpha_3 y_{t-3} + u_t \\
 &= \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + (-\alpha_3)(y_{t-2} - y_{t-3}) + \alpha_3 y_{t-2} + u_t \\
 &= \alpha_1 y_{t-1} + (\alpha_2 + \alpha_3) y_{t-2} + (-\alpha_3)(y_{t-2} - y_{t-3}) + u_t \\
 &= \alpha_1 y_{t-1} + (-\alpha_2 - \alpha_3)(y_{t-1} - y_{t-2}) + (-\alpha_3)(y_{t-2} - y_{t-3}) \\
 &\quad + (\alpha_2 + \alpha_3) y_{t-1} + u_t \\
 &= (\alpha_1 + \alpha_2 + \alpha_3) y_{t-1} + (-\alpha_2 - \alpha_3)(y_{t-1} - y_{t-2}) \\
 &\quad + (-\alpha_3)(y_{t-2} - y_{t-3}) + u_t \\
 &= (\alpha_1 + \alpha_2 + \alpha_3) y_{t-1} + (-\alpha_2 - \alpha_3) \Delta y_{t-1} + (-\alpha_3) \Delta y_{t-2} \\
 &\quad + u_t
 \end{aligned}$$

- ▶ AR(p) proces v tvare

$$y_t = \rho y_{t-1} + \theta_1 \Delta y_{t-1} + \theta_2 \Delta y_{t-2} + \theta_{p-1} \Delta y_{t-p+1} + u_t,$$

sa dá ekvivalentne zapísať ako

$$\Delta y_t = (\rho - 1)y_{t-1} + \theta_1 \Delta y_{t-1} + \theta_2 \Delta y_{t-2} + \theta_{p-1} \Delta y_{t-p+1} + u_t$$

a zaujíma nás potom t-štatistika z koeficienta pri  $y_{t-1}$ .

- ▶ Vo všeobecnosti: proces môže obsahovať konštantu a/alebo lineárny trend

$$\Delta y_t = \alpha + \beta t + (\rho - 1)y_{t-1} + \theta_1 \Delta y_{t-1} + \theta_2 \Delta y_{t-2} + \theta_{p-1} \Delta y_{t-p+1} + u_t$$

## Augmented Dickey-Fuller test (ADF)

- ▶ Wayne A. Fuller (1976), David A. Dickey, Wayne A. Fuller (1979, 1981)
- ▶ Odhadujeme model

$$\Delta y_t = \alpha + \beta t + (\rho - 1)y_{t-1} + \theta_1 \Delta y_{t-1} + \dots + \theta_k \Delta y_{t-k} + u_t,$$

pričom musíme

- ▶ rozhodnúť, či zahrnúť konštantu  $\alpha$  a lineárny trend  $\beta t$  (podľa toho, či ich obsahuje proces  $y$ )
- ▶ určiť  $k$  (podľa informačných kritérií)
- ▶ Zaujímá nás potom t-štatistika zo sigifikancie koeficienta pri  $y_{t-1}$ , ale so správnymi kritickými hodnotami

## ADF test - kritické hodnoty

- ▶ James G. MacKinnon (1991) - dostupné ako súčasť doplnenej verzie z roku 2010:  
<http://ideas.repec.org/p/qed/wpaper/1227.html>
- ▶ Simulačne získané hodnoty:

**Table 1. Response Surface Estimates of Critical Values**

$N$	Variant	Level	Obs.	$\beta_{\infty}$	(s.e.)	$\beta_1$	$\beta_2$
1	no constant	1%	600	-2.5658	(0.0023)	-1.960	-10.04
		5%	600	-1.9393	(0.0008)	-0.398	
		10%	560	-1.6156	(0.0007)	-0.181	
1	no trend	1%	600	-3.4336	(0.0024)	-5.999	-29.25
		5%	600	-2.8621	(0.0011)	-2.738	-8.36
		10%	600	-2.5671	(0.0009)	-1.438	-4.48
1	with trend	1%	600	-3.9638	(0.0019)	-8.353	-47.44
		5%	600	-3.4126	(0.0012)	-4.039	-17.83
		10%	600	-3.1279	(0.0009)	-2.418	-7.58



## ADF test - kritické hodnoty

- ▶ Ak v regresii použijeme  $T$  dát, kritická hodnota je  $\beta_\infty + \beta_1/T + \beta_2/T^2$
- ▶ V našom prípade zo simulácií: konštanta bez trendu,  $T = 200$ :

$N$	Variant	Level	Obs.	$\beta_\infty$	(s.e.)	$\beta_1$	$\beta_2$
1	no trend	1%	600	-3.4336	(0.0024)	-5.999	-29.25
		5%	600	-2.8621	(0.0011)	-2.738	-8.36
		10%	600	-2.5671	(0.0009)	-1.438	-4.48

- ▶ Dostaneme:
  - ▶ pre 1 percento:  $-3.4336 - 5.999/100 - 29.25/200^2 = -3.451$
  - ▶ pre 5 percent:  $-2.8621 - 2.738/200 - 8.36/200^2 = -2.879$
- ▶ Porovnajme s t-rozdelením (úplne iné) a s kvantilmi zo simulácií (ok)


## Časť 4: ADF test v R-ku

## Funkcia `ur.df`

- ▶ Balík `urca` (**ur** = unit root, **ca** = cointegration)
- ▶ Funkcia `ur.df` (**ur** = unit root, **df** = Dickey-Fuller) s parametrami:
  - ▶ `type`: možnosti sú `drift` (konštanta bez lineárneho trendu) `trend` (konštanta aj lineárny trend) `none` (nič)
  - ▶ `lags`: maximálny počet lagov
  - ▶ `selectlags`: kritérium, podľa ktorého sa vyberá počet lagov (informačné kritériá AIC, BIC)

## Príklad použitia

- ▶ Dáta spread z predchádzajúcich prednášok (rozdiel dlhodobej a krátkodobej úrokovej miery)



## ► Spravíme:

```
library(urca)
ur.df(spread,           # data
      type = "drift",   # konstanta bez trendu
      lags = 8,         # 8 lagov = 2 roky
      selectlags = "BIC" # Bayesovo kritérium
    )
```

```
##
```

```
## #####
```

```
## # Augmented Dickey-Fuller Test Unit Root / Cointegration
```

```
## #####
```

```
##
```

```
## The value of the test statistic is: -3.9112 7.6595
```

- Vypíšeme summary, aby sme dostali aj kritické hodnoty

```
summary(ur.df(spread, type = "drift",
              lags = 8, selectlags = "BIC"))
```

- Odhadnutá regresia a testovacia štatistika (vo všeobecnosti je konštantný člen označený ako Intercept a lineárny trend tt):

```
Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.10035    0.05592   1.794 0.074240 .
z.lag.1      -0.10720    0.02741  -3.911 0.000125 ***
z.diff.lag   0.29007    0.06706   4.326 2.38e-05 ***
---
Signif. codes:
  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.7006 on 204 degrees of freedom
Multiple R-squared:  0.1216,    Adjusted R-squared:  0.113
F-statistic: 14.12 on 2 and 204 DF,  p-value: 1.806e-06

Value of test-statistic is: -3.9112 7.6595
```

► Testovacia štatistika a kritické hodnoty

prvá štatistika



Value of test-statistic is: **-3.9112** 7.6595

Critical values for test statistics:

	1pct	5pct	10pct
tau2	<b>-3.46</b>	<b>-2.88</b>	<b>-2.57</b>
phi1	6.52	4.63	3.81



prvý riadok  
kritických hodnôt

- Kritérium: Hypotéza o jednotkovom koreni sa zamieta, ak je štatistika menšia ako kritická hodnota
- V našom prípade
  - hypotézu o jednotkovom koreni zamietame
  - dáta teda netreba diferencovať

## Diferencovanie dát pri hľadaní ARIMA modelu



ARMA modely sú modelmi pre stacionárne dáta  $\Rightarrow$

- ▶ čo sme už vedeli: ak majú trend, treba ich zdiferencovať
- ▶ nové: **ak majú jednotkový koreň, treba ich zdiferencovať**

Postup:

- ▶ ak treba, zdiferencujeme najskôr dáta kvôli odstráneniu trendu
- ▶ potom otestujeme prítomnosť jednotkového koreňa
- ▶ ak v dátach je jednotkový koreň, zdiferencujeme ich a znovu otestujeme na jednotkový koreň (a diferencujeme ďalej, kým nedostaneme dáta bez jednotkového koreňa)
- ▶ pre diferencie, v ktorých už nie je trend ani jednotkový koreň, hľadáme ARMA model

Ak sa dáta diferencujú, tak väčšinou len raz, výnimočne dvakrát.

## Cvičenie: Interpretácia regresie z výstupu

## Zadanie

- ▶ Napíšte regresiu, ktorá sa odhadla v tomto ACF teste.
- ▶ Aká hypotéza o parametroch regresie sa testuje?
- ▶ Odvodte AR model pre dáta, ktorý regresia po úprave definuje.
- ▶ Odvodte, že testovaná hypotéza zodpovedá jednotkovému koreňu

Call:

```
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-2.62437	-0.35488	-0.00071	0.35322	2.54618

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	0.10051	0.05552	1.810	0.071692	.
z.lag.1	-0.10514	0.02800	-3.755	0.000225	***
z.diff.lag1	0.29195	0.06743	4.330	2.32e-05	***
z.diff.lag2	-0.01416	0.06898	-0.205	0.837603	

## Riešenie

Call:  $\Delta z_t \sim z_{t-1} + 1 + \Delta z_{t-1}, \Delta z_{t-2}, \Delta z_{t-3}, \dots$  atd'.  
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:  
Min 1Q Median 3Q Max  
-2.62437 -0.35488 -0.00071 0.35322 2.54618

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	0.10051	0.05552	1.810	0.071692 .
$z_{t-1}$ z.lag.1	-0.10514	0.02800	-3.755	0.000225 ***
$\Delta z_{t-1}$ z.diff.lag1	0.29195	0.06743	4.330	2.32e-05 ***
$\Delta z_{t-2}$ z.diff.lag2	-0.01416	0.06898	-0.205	0.837603

Pre dáta  $z$  sa odhadla regresia

$$\Delta z_t = \alpha + c_1 z_{t-1} + c_2 \Delta z_{t-1} + c_3 \Delta z_{t-2} + \varepsilon_t$$

a testujeme, že koeficient pri  $z_{t-1}$  je nulový, teda že  $c_1 = 0$

- ▶ Upravujeme regresiu na tvar AR procesu pre  $z$ :

$$\Delta z_t = \alpha + c_1 z_{t-1} + c_2 \Delta z_{t-1} + c_3 \Delta z_{t-2} + \varepsilon_t$$

$$z_t - z_{t-1} = \alpha + c_1 z_{t-1} + c_2 (z_{t-1} - z_{t-2}) + c_3 (z_{t-2} - z_{t-3}) + \varepsilon_t$$

$$z_t = \alpha + (1 + c_1 + c_2) z_{t-1} + (-c_2 + c_3) z_{t-2} + (-c_3) z_{t-3} + \varepsilon_t$$

- ▶ Jednotkový koreň v AR modeli je práve vtedy, keď je súčet autoregresných koeficientov rovný 1, t.j.

$$(1 + c_1 + c_2) + (-c_2 + c_3) + (-c_3) = 1$$

$$1 + c_1 = 1$$

$$c_1 = 0$$

## Zadanie II. na samostatnú prácu

Zopakujte pre nasledujúci výstup:

Call:

```
lm(formula = z.diff ~ z.lag.1 - 1 + z.diff.lag)
```

Residuals:

Min	1Q	Median	3Q	Max
-2.9585	-0.4996	0.2749	0.7940	3.1786

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
z.lag.1	-0.17906	0.09112	-1.965	0.052426	.
z.diff.lag1	-0.59969	0.11658	-5.144	1.51e-06	***
z.diff.lag2	-0.40873	0.11889	-3.438	0.000882	***
z.diff.lag3	-0.30658	0.10005	-3.064	0.002863	**