

# Úvod, základné pojmy, testovanie bieleho šumu

Beáta Stehlíková

2-PMS-10 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

## Analýza časových radov: úvod

## Klasický vzorový príklad

- ▶ Pozrieme sa na dáta - počty cestujúcich aerolinkami
- ▶ Dáta AirPassengers z balíka datasets
- ▶ Popis dát v dokumentácii (pomocou ?AirPassengers):
  - ▶ The classic Box & Jenkins airline data. Monthly totals of international airline passengers, 1949 to 1960.
  - ▶ A monthly time series, in thousands.


```
library(datasets)
```

```
AirPassengers
```

```
##           Jan Feb Mar Apr May Jun Jul Aug Sep Oct Nov Dec
## 1949    112 118 132 129 121 135 148 148 136 119 104 118
## 1950    115 126 141 135 125 149 170 170 158 133 114 140
## 1951    145 150 178 163 172 178 199 199 184 162 146 166
## 1952    171 180 193 181 183 218 230 242 209 191 172 194
## 1953    196 196 236 235 229 243 264 272 237 211 180 2013/62
```


## Klasický vzorový príklad - priebeh dát

Stačí plot (AirPassengers) a vďaka časovej štruktúre dát máme:




## Klasický vzorový príklad - priebeh dát

Po zlogaritmovaní sa stabilizuje volatilita:



## Box a Jenkins

Budeme sa zaoberať **prístupom od Boxa a Jenkinsa**.



Rozhovor s G. E. P. Boxom po oslave jeho 80. narodenín (1999), ako sa začal zaujímať o štatistiku a ďalšie otázky.

*The first paper you wrote with Jenkins has been considered as a breakthrough in statistics.*

Peña, D. (2001). George Box: An interview with the International Journal of Forecasting. International Journal of Forecasting, 17(1), 1-9.

Odkaz na článok s rozhovorom:

<https://www.sciencedirect.com/science/article/pii/S0169207000000613>

## Informačný list predmetu

### Výsledky vzdelávania:

*Študenti sa oboznámia s Box-Jenkinsovou metodológiou modelovania časových radov pomocou ARIMA procesov. Budú poznať teoretické vlastnosti týchto modelov a budú ich vedieť použiť na analýzu reálnych dát.*

## Základné pojmy



## Obsah

- ▶ Časový rad, momenty
- ▶ Stacionarita, ergodicita
- ▶ Biely šum
- ▶ Autokorelačná funkcia
- ▶ Woldova reprezentácia
- ▶ Testy o autokorelačnej funkcii

## Momenty časového radu

- ▶ Náhodný proces  $x_1, x_2, \dots, x_T$  je úplne charakterizovaný svojou  $T$ -rozmernou distribučnou funkciou
- ▶ Obvykle sa zameriavame na **prvé dva momenty**:
  - ▶ stredná hodnota  $E(x_t)$
  - ▶ variancia  $D(x_t)$
  - ▶ kovariancie  $Cov(x_t, x_s)$ , tzv. **autokovariancie**

## Stacionarita a ergodicita

- ▶ Väčšinou máme len jeden časový rad - jednu realizáciu náhodného procesu → aby sa dala robiť štatistická inferencia, potrebujeme dodatočné predpoklady
- ▶ Napríklad: na to, aby sme odhadli strednú hodnotu, ... potrebujeme viac ako jednu realizáciu tejto náhodnej premennej
- ▶ **Ergodický proces** - výberové momenty počítané z časového radu s  $T$  pozorovaniami konvergujú pre  $T \rightarrow \infty$  k zodpovedajúcim momentom
- ▶ Tento koncept má zmysel iba ak predpokladáme, že  $E(x_t) = \mu$ ,  $D(x_t) = \sigma^2, \dots$  pre každé  $t$

## Stacionarita a ergodicita

- ▶ **Silná stacionarita**: združená distribučná funkcia sa nemení pri posune v čase
- ▶ Obvykle sa pracuje so slabším predpokladom → **slabá stacionarita**:

$$E(x_t) = \mu \quad \forall t \quad (1)$$

$$\text{Cov}(x_t, x_s) = \gamma(|t - s|) \quad \forall t, s \quad (2)$$

- ▶ Z (2) vyplýva, že  $D(x_t) = \text{const.}$  pre všetky  $t$ .
- ▶ Ďalej budeme pod stacionaritou rozumieť slabú stacionaritu.

## Stacionarita - dáta


- ▶ *Stacionárny časový rad:*
  - ▶ dáta sú priťahované k určitej rovnovážnej hodnote, okolo ktorej oscilujú
- ▶ *Nestacionárny časový rad:*
  - ▶ napríklad trend: rastúci trend → stredná hodnota nie je konštantná → proces nie je stacionárny
  - ▶ neskôr budeme vidieť aj iné druhy nestacionarity (napr. zatiaľ nejasne znejúci pojem *jednotkový koreň* v sylabe predmetu)

# PRIKLAD 1

# Japanese motor vehicle production in thousand (1947-1989)

```
library(fma)
```

```
plot(jcars)
```




## # PRIKLAD 2

# *Rocny prietok Nilu v Aswane v  $10^8 m^3$  (stavba priehrad)*

```
library(datasets)
```

```
plot(Nile)
```



## Nepovinné poznámky: Hľadanie bodov zmeny


- ▶ Tutoriál (useR! International R User 2017 Conference):  
<https://www.youtube.com/watch?v=l7jUBro78RM>
- ▶ Diplomovka Lucie Macháčkovej, zmeny v prietokoch slovenských riek (mEMM 2020, školiteľ: doc. Pekár)
- ▶ Článok s prehľadom rôznych metód: *Aminikhanghahi, S., & Cook, D. J. (2017). A survey of methods for time series change point detection. Knowledge and information systems, 51(2), 339-367.*  
<https://link.springer.com/article/10.1007/s10115-016-0987-z>

*# pozrime sa na prietoky Nilu:*

```
library(changepoint)
zmena <- cpt.mean(Nile)
plot(zmena)
```



Výstup z predchádzajúceho slajdu:



# Biely šum

## Definícia bieleho šumu

- ▶ Dôležitý príklad stacionárneho procesu, pomocou ktorého budeme definovať aj rôzne modely pre dáta
- ▶ Biely šum  $u_t$  je náhodný proces s nasledujúcimi vlastnosťami

$$\mathbb{E}(u_t) = 0 \quad \forall t$$


$$\mathbb{D}(u_t) = \sigma^2 \quad \forall t$$

$$\text{Cov}(u_t, u_s) = 0 \quad \forall t \neq s$$

- ▶ Napríklad postupnosť nezávislých náhodných premenných s rovnakým rozdelením (a konečnou strednou hodnotou a disperziou), ale nie je to jediná možnosť

## Príklad

```
x <- rnorm(100)
plot(x, type = "l")
```



## Príklady: zisťovanie stacionarity procesu

## Príklad 1

- ▶ Nech  $u_t$  je biely šum, definujme

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

- ▶ Platí:


$$\mathbb{E}(x_t) = 0, \mathbb{D}(x_t) = 2\sigma^2$$

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

- ▶ Proces teda **je stacionárny**

## Príklad 1: simulácia priebehu procesu, $N = 200$ pozorovaní

```
u <- rnorm(N + 1)
x <- u[2:N] + u[1:(N - 1)]
```



## Príklad 2

- ▶ Nech  $u_t$  je biely šum, definujme

$$x_t = \begin{cases} u_1 & \text{pre } t = 1, \\ x_{t-1} + u_t & \text{pre } t = 2, 3, \dots \end{cases}$$

- ▶  $x_t$  sa dá zapísať v tvare  $x_t = \sum_{i=1}^t u_i$
- ▶ Platí:

$$\mathbb{E}(x_t) = 0, \mathbb{D}(x_t) = t\sigma^2$$



$$\text{Cov}(x_t, x_{t+k}) = t\sigma^2 \quad \text{pre } k > 0$$

- ▶ Proces teda **nie je stacionárny** (to vieme povedať už po výpočte disperzie)



## Príklady 1, 2: porovnanie simulácií procesov

- ▶ Vľavo: stacionárny proces z príkladu 1, vpravo: proces s rastúcou disperziou z príkladu 2



## Príklad 3

- ▶ Nech  $u_t$  je biely šum, definujme

$$x_t = \mu + \sum_{j=0}^{\infty} \psi_j u_{t-j}, \quad (3)$$

kde koeficienty  $\psi_j$  spĺňajú  $\psi_0 = 1$ ,  $\sum \psi_j^2 < \infty$



- ▶ Platí:

$$\mathbb{E}(x_t) = \mu, \mathbb{D}(x_t) = \sigma^2 \sum_{j=1}^{\infty} \psi_j^2$$

$$\text{Cov}(x_t, x_{t+k}) = \sigma^2 \sum_{j=0}^{\infty} \psi_j \psi_{k+j}$$

- ▶ Proces **je stacionárny**.

## Woldova reprezentácia



Having discussed a number of types of random processes, the author furnishes proofs of their various properties, and then gives a theorem of considerable interest, concerning the structure of the most general discrete stationary process. This, in fact, can always be presented as a sum of two components the nature of which is known.

J. N. (1939). *Journal of the Royal Statistical Society*, 102(2), 295-298.

<https://archive.org/details/in.ernet.dli.2015.262214>

<https://www.jstor.org/stable/298000>

<https://digitaltmuseum.se/021016543711/professor-herman-wold-uppsala-1969>

## Woldova reprezentácia stacionárneho procesu

- ▶ V príklade 3: Proces tvaru (3) je stacionárny
- ▶ Dá sa dokázať: Každý stacionárny proces  $x_t$  sa dá zapísať v tvare

$$x_t = \mu_t + \sum_{j=0}^{\infty} \psi_j u_{t-j}$$





kde  $u$  je biely šum,  $\psi_0 = 1$ ,  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$  a  $\mu_t$  sa dá presne predikovať z predchádzajúcich hodnôt procesu  $x$  (v našich aplikáciách to bude konštanta)

- ▶ Toto vyjadrenie sa nazýva **Woldova reprezentácia**

## Autokorelačná funkcia (ACF)

## Motivácia

- Hore:  $u_t$ , dolu:  $x_t = 0.9x_{t-1} + u_t$  - simulácia a závislosť  $x_t$  od  $x_{t-1}$



## Definícia základné vlastnosti

- ▶ Autokorelačná funkcia (ACF) stacionárneho procesu je definovaná ako

$$\rho(\tau) = \text{cor}(x_t, x_{t+\tau}) = \frac{\text{cov}(x_t, x_{t+\tau})}{\sqrt{\mathbb{D}(x_t)\mathbb{D}(x_{t+\tau})}}$$

- ▶ ACF sa teda dá vyjadriť pomocou autokovariančnej funkcie  $\gamma$ :

$$\rho(\tau) = \frac{\gamma(\tau)}{\gamma(0)},$$

- ▶ Platí:

$$\rho(0) = 1, \rho(-\tau) = \rho(\tau),$$

stačí nám teda počítať  $\rho(\tau)$  pre  $\tau = 1, 2, \dots$



## Príklad

- ▶ Nech  $u_t$  je biely šum, definujme

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

- ▶ Pre tento proces sme odvodili stacionaritu a vlastnosti:

$$\mathbb{D}(x_t) = 2\sigma^2, \text{Cov}(x_t, x_{t+k}) = \begin{cases} \sigma^2 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

- ▶ ACF teda je

$$\rho(k) = \text{Cor}(x_t, x_{t+k}) = \begin{cases} 1/2 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

## Odhadovanie ACF z dát

- ▶ Ergodický proces  $\rightarrow$  stredná hodnota, disperzia a autokovariancie sa dajú konzistentne odhadnúť z dát  $x_1, \dots, x_T$ :

$$\hat{\mu} = \frac{1}{T} \sum_{t=1}^T x_t, \quad \hat{\gamma}(0) = \frac{1}{T} \sum_{t=1}^T (x_t - \hat{\mu})^2$$

$$\hat{\gamma}(\tau) = \sum_{t=1}^{T-\tau} (x_t - \hat{\mu})(x_{t+\tau} - \hat{\mu})$$


- ▶ Z toho - konzistentný odhad autokorelačnej funkcie:

$$\hat{\rho}(\tau) = \frac{\hat{\gamma}(\tau)}{\hat{\gamma}(0)}$$

- je asymptoticky nevychýlený

## Odhadovanie ACF z dát v R-ku: funkcia acf

```
acf(x) # pre data x <- u[2:N] + u[1:(N - 1)]
```



## Využitie na kontrolu výpočtov


- ▶ *Zadanie:* Nech  $z_t$  je proces, ktorého hodnoty sú nezávislé náhodné premenné s rozdelením  $N(0, 1)$ . Ukážte, že nasledujúci proces je stacionárny a vypočítajte jeho ACF:

$$y_t = \begin{cases} z_t & \text{pre } t \text{ nepárne} \\ \frac{1}{\sqrt{2}}(z_{t-1}^2 - 1) & \text{pre } t \text{ párne} \end{cases}$$

- ▶ Vygenerujeme si daný proces a zobrazíme odhadnutú ACF (náš výpočet by mal dať podobný výsledok):


```
set.seed(1234)
N <- 500
z <- rnorm(N, mean = 0, sd = 1)
y <- z # pre nepárne indexy zostane, párne upravíme
ind.párne <- seq(from = 2, to = N, by = 2)
y[ind.párne] <- (1/sqrt(2)) * (z[ind.párne - 1]^2 - 1)
```

`acf(y)`



Alternatíva: funkcia `acf1` z balíka `astsa`

```
library(astsa); acf1(y)
```



## Testovanie nulovosti autokorelácií

## Testovanie nulovosti autokorelácií - každej samostatne

- ▶ Biely šum má nulovú ACF  $\Rightarrow$  pri testovaní, či sú dáta bielym šumom, budeme testovať, či majú nulové autokorelácie
- ▶ Odhad ACF v prípade bieleho šumu
  - ▶ asymptoticky nevychýlený
  - ▶ disperzia  $\approx 1/T$
  - ▶  $\Rightarrow$  približný 95 % interval spoľahlivosti:  $\pm 1.96/\sqrt{T}$ , resp.  $\pm 2/\sqrt{T}$  - často sa zobrazuje spolu s odhadnutými autokoreláciami (aj v prípade funkcií `acf` a `acf1`)
- ▶ Pre každú autokoreláciu samostatne:
  - ▶ Testujeme, či sa rovná nule.
  - ▶ Nulovú hypotézu zamietame, ak je jej odhad mimo intervalu spoľahlivosti



Ak testujeme nulovosť autokorelácie, nie pre biely šum:

- ▶ V prípade procesu, pre ktorý platí  $\rho(\tau) = 0$  pre  $\tau > k$ , pre tieto  $\tau$  platí

$$\mathbb{D}(\hat{\rho}(\tau)) \approx \frac{1}{T} \left( 1 + 2 \sum_{j=1}^k \hat{\rho}(j)^2 \right)$$

## Testovanie nulovosti autokorelácií - Ljung-Boxov test

- ▶ Netestujeme nulovosť každej autokorelácie samostatne, ale testujeme hypotézu  $\rho(1) = \rho(2) = \dots = \rho(m) = 0$
- ▶ **Box & Pierce, 1970:** ak platí  $H_0$ , asymptoticky

$$Q = T \sum_{j=1}^m \hat{\rho}(j)^2 \sim \chi_m^2$$

- ▶ **Ljung & Box, 1978:** modifikácia s lepšími vlastnosťami pri menšom počte dát

$$Q = T(T+2) \sum_{j=1}^m \frac{\hat{\rho}(j)^2}{T-j} \sim \chi_m^2$$

- ▶ *Poznámka, ktorú využijeme neskôr: Počet stupňov voľnosti sa zmení, ak ide o rezíduá z modelu*

## Ljung-Boxov test v R-ku: funkcia Box.test

- ▶ Testujme pre dáta  $x$ , že prvé tri autokorelácie sú nulové


```
set.seed(12345)
x <- rnorm(N)

Box.test(x, lag = 3, type = "Ljung-Box") # staci `Ljung`

##
## Box-Ljung test
##
## data:  x
## X-squared = 0.9611, df = 3, p-value = 0.8107
```

## Užitočný výstup pre LB test: rôzny počet lagov

- Zobrazíme hranicu 0.05 a P hodnoty (prístup napr. `Box.test(x, lag = 3, type = "Ljung")$p.value`):



# Cvičenia

## Cvičenie 1: Ljung-Boxov test - opakovanie

```
##
```

```
## Box-Ljung test
```

```
##
```

```
## data: x
```

```
## X-squared = 4.4469, df = 3, p-value = 0.2171
```

- ▶ Aká hypotéza sa tu testuje?
- ▶ Vysvetlite, čo presne znamenajú hodnoty uvedené s popisom X-squared, df a p-value.
- ▶ Zamietame nulovú hypotézu alebo nie?
- ▶ Čo nám tento test hovorí o dátach? Môže ísť o biely šum alebo je to nepravdepodobné? Aké ďalšie testy by ste spravili, aby ste vedeli lepšie odpovedať na túto otázku?

- ▶ Ako sa počíta testovacia štatistika?
- ▶ Vypočítajte jej hodnotu, ak viete, že dáta obsahujú 50 pozorovaní a prvé hodnoty autokorelačnej funkcie sú nasledovné:

```
acf(x, lag.max = 5, plot = FALSE)
```

```
##  
## Autocorrelations of series 'x', by lag  
##  
##      0      1      2      3      4      5  
## 1.000 0.026 -0.171 0.226 -0.106 0.048
```

Až na zaokrúhľovacie chyby nám má výjsť výsledok z výstupu testu (ten sa počíta z presných, nie zaokrúhlených hodnôt ACF).

## Cvičenie 2: Ljung-Boxov test pre prietoky Nílu

- ▶ Uvažujme dáta o prietoku Nílu z prednášky po postavení priehrad, napr. od roku 1910. Sú v premennej Nile, ktorá je typu `ts` (*time series*):

```
class(Nile)
```

```
## [1] "ts"
```

- ▶ Kratší časový rad z nej vytvoríme pomocou funkcie `window` s parametrami `start` a/alebo `end`:

```
x <- window(Nile, start = 1910)
```

- ▶ Zobrazte ACF a LB testom testujte hypotézu, že hladiny Nílu sú nekorelované, výsledok zobrazte graficky (ako na str.44).



## Cvičenie 3: Ljung-Boxov test pre úrokové miery

- ▶ Budeme analyzovať dáta dlhodobých úrokových mierach z Európskej centrálnej banky, pričom použijeme mesačné dáta z obdobia 20 rokov (2001-2021). Využijeme ich aj neskôr, pri ďalších témach.

<https://sdw.ecb.europa.eu/browse.do?node=bbn4864>

- ▶ Na stránke predmetu je csv-súbor stiahnutý z webu ECB v auguste (pri aktuálnom stiahnutí bude obsahovať aj novšie dáta).

	A	B	C	
1	Data Source in SDW: <a href="https://sdw.ecb.europa.eu/browse.do?node=bbn4864">https://sdw.ecb.europa.eu/browse.do?node=bbn4864</a>			
2		IRS.M.AT.L.L40.CI.0000.EUR.N.Z	IRS.M.BE.L.L40.CI.0000.EUR.N.Z	IRS.M.BG.L.L40.CI.0000.EUR.N.Z
3		Austria, Euro	Belgium, Euro	Bulgaria, Bulgarian Lev
4	Collection:	Average of observations through period (A)	Average of observations through period (A)	Average of observations through period (A)
5	Period/Unit:	[Percent ]	[Percent ]	[Percent ]
6	2022Jul	1.70	1.80	1.85
7	2022Jun	2.07	2.13	1.77
8	2022May	1.54	1.58	1.62
9	2022Apr	1.29	1.30	1.62
10	2022Mar	0.72	0.79	1.09
11	2022Feb	0.54	0.59	0.61
12	2022Jan	0.18	0.26	0.57

## ▶ Načítame dáta:

```
# DOPLNTE
data <- read.csv(      ,      # cesta k suboru
                  skip = , # vynechanie riadkov,
                  # chceme iba data
                  header = FALSE, # vynechali sme riadky
                  row.names = 1) # prvý stĺpec nie sú data
                                # tieto daty použijeme
                                # ako názvy riadkov
```

```
head(data)
```

```
##           V2      V3      V4      V5      V6      V7      V8      V9      V10
## 2021Dec -0.05  0.03  0.44  0.64  2.62 -0.38 -0.08  0.11  0.41
## 2021Nov -0.01  0.07  0.25  0.55  2.62 -0.31  0.01  0.20  0.47
## 2021Oct  0.08  0.16  0.25  0.39  2.34 -0.21  0.10  0.18  0.47
## 2021S...  0.00  0.01  0.15  0.00  1.00  0.00  0.01  0.00  0.00
```

- ▶ Získajte zo súboru s dátami názvy (štáty a meny):

```
# DOPLNTE
```

```
nazvy <- read.csv(...)
```

```
head(nazvy)
```

```
##      [,1]  
## [1,] "Austria, Euro"  
## [2,] "Belgium, Euro"  
## [3,] "Bulgaria, Bulgarian lev"  
## [4,] "Cyprus, Euro"  
## [5,] "Czech Republic, Czech koruna"  
## [6,] "Germany, Euro"
```

- Teraz môžeme priradiť stĺpcom ich názvy a získať dáta, s ktorými budeme ďalej pracovať:

```
colnames(data) <- nazvy
head(data)
```

```
##          Austria, Euro Belgium, Euro Bulgaria, Bulgarian
## 2021Dec          -0.05          0.03
## 2021Nov          -0.01          0.07
## 2021Oct           0.08          0.16
## 2021Sep          -0.08          0.01
## 2021Aug          -0.23         -0.14
## 2021Jul          -0.13         -0.03
##          Czech Republic, Czech koruna Germany, Euro Denma
## 2021Dec                2.62          -0.38
## 2021Nov                2.62          -0.31
## 2021Oct                2.34          -0.21
## 2021Sep                1.99          -0.22
```


- ▶ V tomto cvičení zoberieme dáta pre Rakúsko:

```
x <- data[, "Austria, Euro"]  
x <- x[length(x):1] # usporadame od najstarsich
```

- ▶ Z vektora spravíme časový rad funkciou `ts` s parametrami:
  - ▶ použité dáta
  - ▶ `frequency` - frekvencia dát: 1 pre ročné dáta, 4 pre kvartálne, 12 pre mesačné
  - ▶ `start` alebo `end` - v závislosti od frekvencie, napr. `start = 2000` pri ročných dátach, `start = c(2000, 1)` pri kvartálnych znamená prvý kvartál roku 2000
- ▶ My máme mesačné dáta so začiatkom v januári 2001 (a koncom v decembri 2021)

```
# DOPLNTE  
x <- ts(x, ....)
```

## plot(x)



- ▶ Vidíme klesajúci trend, dáta preto nie sú stacionárne (a nemôžeme napríklad odhadovať ACF). **Budeme preto pracovať s diferenciami** (teda medzimesačnými zmenami).
- ▶ **Vytvoríme diferencie pomocou funkcie `diff`** - napríklad:

```
# numericky vektor  
y <- c(1, 4, 6, 2)  
diff(y)
```

```
## [1] 3 2 -4
```

```
# casove rady  
z <- ts(y, frequency = 12, start = c(2022, 1))  
diff(z)
```

```
##      Feb Mar Apr  
## 2022  3  2  -4
```

- ▶ Vytvorte vektor diferencií úrokových mier a zobrazte ich.

```
# DOPLNTE  
xDif <- ...  
plot(xDif)
```

```
head(xDif) # pre kontrolu
```

```
##          Feb   Mar   Apr   May   Jun   Jul  
## 2001  0.00 -0.09  0.15  0.18 -0.07  0.02
```

- ▶ **Zaujíma nás, či sú tieto diferencie korelované alebo či ich môžeme považovať za biely šum.**
  - ▶ Zobrazte ACF. Ktoré autokorelácie sú signifikantné?
  - ▶ Zobrazte výsledky LB testu pre rôzne lags a skomentujte.
  - ▶ Zhodnoťte výsledky. Aký je váš záver ohľadom charakteru daného časového radu?



## Cvičenie 4: Testovacia štatistika Ljung-Boxovho testu

- ▶ Vygenerujme si dáta, ktoré **sú** nekorelované. Napríklad:

```
x <- rnorm(100, mean = 10, sd = 3) # iid  $N(10, 3^2)$ 
```


- ▶ Budeme testovať hypotézu, že prvých 5 autokorelácií je nulových a zaznamenáme hodnotu testovacej štatistiky:

```
# DOPLNTE
simulacia <- function(){
  x <- rnorm(100, mean = 10, sd = 3)
  LB <- Box.test(x, ...)
  return(...)
}
```

- ▶ Zopakujeme 1000 krát - pri opakovaní simulácií je užitočná funkcia `replicate` - a zobrazíme histogram:

```
statistiky <- replicate(1000, simulacia())  
hist(statistiky)
```

- ▶ Aká je teoretická hustota rozdelenia štatistiky v Ljung-Boxovom teste? Porovnajzte so získaným histogramom.
- ▶ Ukážka výstupu (kvôli náhodnosti môžete dostať iný):



- ▶ Zopakujte simulácie, histogram a jeho porovnanie s hustotou, kvantil a jeho porovnanie s kritickou hodnotou testu:
  - ▶ pre iný počet dát
  - ▶ pre iné rozdelenie generovaných iid náhodných veličín
  - ▶ pre dáta, ktoré nie sú iid, ale sú bielym šumom
  - ▶ pre iný počet lagov

## Cvičenie 5: Sila Ljung-Boxovho testu

- ▶ Vypočítajte ACF procesu  $x_t = u_t - \beta u_{t-1}$ , kde  $u_t$  je biely šum (na prednáške sme mali prípad  $\beta = -1$ ).
- ▶ Pre  $\beta \neq 0$  dostaneme nenulovú prvú hodnotu ACF. LB testom budeme testovať, či sú prvé dve hodnoty ACF nulové. Skutočnosť je samozrejmá, že nie sú.


```
set.seed(123) # kvoli reprodukovateľnosti
N <- 101
u <- rnorm(N, mean = 0, sd = 1)
x <- u[1:(N - 1)] + 3 * u[2:N] # 100 hodnot procesu
                                # beta = -3
LB <- Box.test(x, lag = 2, type = "Ljung-Box")
LB$p.value
```

```
## [1] 0.03218388
```

- ▶ Dal Ljung-Boxov test v predchádzajúcej simulácii správny výsledok?
- ▶ Napíšte funkciu, ktorá pre zadaný parameter procesu  $\beta$  a dĺžku časového radu vráti TRUE/FALSE podľa toho, či sa nulová hypotéza zamietla. Pomocou `simulate` odhadnite, aká je pravdepodobnosť toho, že sa testovaná hypotéza zamietne.
- ▶ Graficky zobrazte odhadnutú silu testu ako funkciu parametra procesu  $\beta$ .
- ▶ Zobrazte aj funkciu, ktorá vyjadruje závislosť  $ACF(1)$  od parametra  $\beta$  a vysvetlite, ako súvisia priebehy týchto dvoch funkcií .

## Cvičenie 6: Teoretické príklady

- ▶ Výpočet strednej hodnoty, disperzie, autokovariancií a autokorelácií.
- ▶ Overovanie stacionarity.



- ▶ Jonathan D. Cryer, Kung-Sik Chan: *Time Series Analysis With Applications in R. Second Edition*. Springer, New York, 2008
- ▶ Cvičenia ku kapitole 2: **2.4–2.16**
- ▶ Dostupné zo školskej siete:  
<https://link.springer.com/book/10.1007/978-0-387-75959-3>