

# Časové řady

Alena Černíková

[alena.cernikova@ujep.cz](mailto:alena.cernikova@ujep.cz)

18. února 2025

# Podmínky zápočtu

- **docházka**
- **semestrální práce**  
zadaná bude cca v půlce semestru  
bude zahrnovat aplikaci většího množství postupů  
důraz bude kladen na komentáře a interpretace  
součástí bude obhajoba minimálně přede mnou a dr.  
Škvorem

# Obsah kurzu

- Úvod
- Dekompozice časových řad – trend
  - klouzavé průměry
  - exponenciální vyrovnávání
- Dekompozice časových řad – sezónnost
- Náhodná složka
- Indexace
- R/S analýza a Hurstův exponent
- Box-Jenkinsova metodologie – ARIMA modely
- Předpovědi
- Regresní závislost v časových řadách

# Časová řada

## Co je časová řada


- soubor pozorování, realizací jedné náhodné veličiny  $y_t$ , kde  $t$  je čas
- čas může být diskrétní  $t \in \{1, 2, \dots, n\}$ , nebo i spojitý  $t \in \langle 0, 1 \rangle$
- důležité je, že pozorování nejsou nezávislá, ale jsou **závislá v čase**
- platí zde jiná pravidla při inferenci

## Příklad.


- *Tlak pacienta měřený vždy v 7 hodin ráno.*
- *Měsíční průměrný kurz eura dle ČNB.*
- *Venkovní teplota měřená na stejném místě každou hodinu.*

# Grafické zobrazení

Vyvoj plodnosti v CR



Pocty narozených v New Yorku



# Časová řada

## Intervaly mezi dvěma sousedními měřeními

- předpokládá se, že jednotlivá pozorování mají mezi sebou stejné časové intervaly
- situace, v nichž se dělají opakovaná měření s různými časovými rozestupy vedou na jiné modely (longitudinal models) a nebudeme se jimi na tomto kurzu zabývat

# Cíl analýzy časových řad

- **pochopení** mechanismu, který časovou řadu generuje
  - **dekompozice časové řady** – hledání trendu, sezónnosti, cykličnosti
  - **Box-Jenkinsova metodologie** – hledání časové závislosti mezi pozorováními
- konstrukce předpovědí vycházející jak ze závislosti na minulých hodnotách, tak z trendů
  - bodové a intervalové předpovědi
  - budeme brát pouze kvantitativní předpovědi získané exaktními výpočty (expertní předpovědi necháme expertům)
- zkoumání závislosti mezi časovými řadami

# Typy časových řad

Časové řady mohou být **diskrétní** nebo **spojité**

- Příklady **diskrétních** řad
  - **binární proces** – hod mincí: řadu hodnot *panna, orel*
  - **náhodná procházka** – částice vycházející z bodu nula a v každém kroku se s  $p$  posune doprava a s  $q$  se posune doleva: řada bodů, ve kterých se částice nachází v čase  $t$
  - **Poissonův proces** – př. počet hovorů na telefonní ústředně v čase  $t$ 
    - počet hovorů za jednu časovou jednotku má Poissonovo rozdělení s intenzitou  $\lambda$ , počty za jednotlivé jednotky jsou vzájemně nezávislé
    - délka doby mezi dvěma hovory má exponenciální rozdělení s parametrem  $\lambda$  a jednotlivé doby mezi hovory jsou vzájemně nezávislé
    - získáváme rostoucí posloupnost počtu hovorů až do času  $t$
- Kurz se bude věnovat převážně **spojitým** časovým řadám



# Na co si dát pozor

Při sběru dat je potřeba ohlídat možné **problémy**

- Jaké zvolit body/okamžiky, kdy se bude časová řada měřit
- **Problém s kalendářem** – vzniká především u měsíčních ekonomických časových řad
  - různé měsíce mají různé počty dní
  - různé měsíce mají různé počty pracovních dní a víkendů
  - speciální pozornost je třeba věnovat pohyblivým svátkům
  - je potřeba volit vhodnou standardizaci, aby byly hodnoty srovnatelné
- **Délka časové řady** – je třeba zvolit dostatečně dlouhou řadu, aby v ní byl vidět aktuální trend, ale zase ne moc dlouhou, aby v ní byly prehistorická data, která mi aktuální trend zakryjí

# Metody analýzy časových řad

- **Indexace** – doc. Sixta
  - výpočet speciálních indexů popisujících časovou řadu
- **Dekompozice** – já + doc. Vozár
  - analýza systematických složek řady
  - hledání trendu, sezónnosti, cykličnosti
- **Box-Jenkinsova metodologie**
  - analýza náhodné složky
  - hledání korelační struktury řady
- **Spektrální analýza**
  - myšlenka je, že časová řada je směs složek/sinusoid s různými frekvencemi
  - převádí se z časové složky na frekvenční složku
  - speciální nástroje: periodogram, spektrální hustota
- **R/S analýza a Hurstův exponent** – dr. Škvor

# Dekompozice časových řad

Předpokládáme, že řada se řídí jedním z následujících dvou modelů

- **Aditivní model**

$$Y_t = Tr_t + C_t + S_t + \varepsilon_t$$

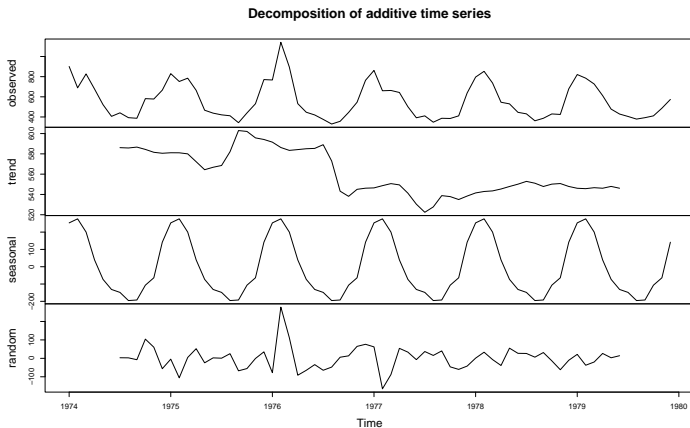
- **Multiplikativní model**

$$Y_t = Tr_t \times C_t \times S_t \times \varepsilon_t$$

kde

- $Y_t$  – časová řada
- $Tr_t$  – dlouhodobý/časový trend
- $C_t$  – cyklická složka – dlouhodobé cykly, které většinou neumíme odhadnout, proto se tato složka odhaduje společně s trendem
- $S_t$  – sezónní složka
- $\varepsilon_t$  – náhodná složka

# Dekompozice časových řad




# Časový trend

## Ukázka základních časových trendů




### Konstantní trend

$$Tr_t = \beta_0$$




### Kvadratický trend

$$Tr_t = \beta_0 + \beta_1 t + \beta_2 t^2$$




### Lineární trend

$$Tr_t = \beta_0 + \beta_1 t$$



### Exponenciální trend

$$Tr_t = \alpha \beta^t$$




# Základní časové trendy

- Logistický trend

$$Tr_t = \frac{\gamma}{1 + \alpha\beta^t}$$

$$\alpha > 0, 0 < \beta < 1, \gamma > 0$$



- Gompertzova křivka

$$Tr_t = \exp(\gamma + \alpha\beta^t)$$

$$\alpha < -1, 0 < \beta < 1$$



- Logistický trend je symetrický kolem inflexního bodu  $-\log \alpha / \log \beta$
- Gompertzova křivka není symetrická kolem inflexního bodu  $-\log(-\alpha) / \log \beta$

# Informativní testy na typ trendu

Trend	test
Lineární	první difference $\delta y_t = y_{t+1} - y_t$ je konstantní
Kvadratický	druhá difference $\delta^2 y_t = \delta y_{t+1} - \delta y_t$ je konstantní
Exponenciální	podíl $y_{t+1}/y_t$ je konstantní
Logistický	podíl $(1/y_{t+2} - 1/y_{t+1})/(1/y_{t+1} - 1/y_t)$ je konstantní
Gompertz	podíl $(\log(y_{t+2}) - \log(y_{t+1})) / (\log(y_{t+1}) - \log(y_t))$ je konstantní

# Informační kritéria

Hodnocení kvality modelu Informační kritéria jsou založena na

- věrohodnosti modelu ( $L$  - *likelihood*)  
ukazatel, jak dobře model kopíruje data
- počtu parametrů použitých v modelu ( $k$ )

Věrohodnost se penalizuje složitostí modelu.

- Chceme model, který dobře kopíruje data a je co možná nejjednodušší
- Čím menší hodnota kritéria, tím lepší je model



# Informační kritéria

## Hodnocení kvality modelu

- **Akaikeho informační kritérium (AIC):**

$$AIC = 2k - 2 \ln(L)$$

- **Upravené Akaikeho informační kritérium (AICc)** pro malé vzorky:

$$AICc = AIC + \frac{2k(k+1)}{n-k-1}$$

- **Bayesovské informační kritérium (BIC):**

$$BIC = \ln(n)k - 2 \ln(L)$$

# Metoda klouzavých průměrů

Předpokládejme řadu, která je tvořena pouze trendovou a náhodnou složkou

$$Y_t = Tr_t + \varepsilon_t$$

- trend mění v čase svůj charakter
- nelze v celé délce popsat jedním funkčním předpisem
- funkční předpis lze aplikovat pouze lokálně, v okolí nějakého bodu
- př. celá řada se neřídí lineárním trendem, ale její trend je lineární v určitých časových intervalech

V takové případě se využívá tzv. **adaptivní přístup** ke trendové složce, kdy se parametry prokládaného modelu mění v čase.

# Metoda klouzavých průměrů

Nejjednodušší způsob, jak najít takový trend, tedy vyhladit časovou řadu, je použít klouzavé průměry. Vyhlazená hodnota v čase  $t$  se pak vypočte jako


$$\hat{Y}_t = \frac{\sum_{\tau=-m}^m Y_{t+\tau}}{2m+1}$$

- vyhlazují pomocí hodnot na obě strany od času  $t$
- klouzavé průměry délky  $2m + 1$  – liché číslo
- délka klouzavých průměrů závisí na požadované míře vyhlazení
- větší délka dá hladší křivku
- jednoduché klouzavé průměry uvažují **lokálně lineární** trend


# Metoda klouzavých průměrů

## Různé délky klouzavých průměrů


### Vyvoj plodnosti v ČR




### Klouzave průmery delky 5



### Klouzave průmery delky 9



### Klouzave průmery delky 15



# Metoda klouzavých vážených průměrů

Někdy nemusí vyhlazení lokálně lineárním trendem dostačovat a je třeba volit lokálně polynomiální trend vyššího řádu.

Výsledkem jsou pak klouzavé vážené průměry.

Jako příklad uvažujme vyhlazení lokálně kubickým trendem

$$Tr(t)_\tau = \beta_0(t) + \beta_1(t)\tau + \beta_2(t)\tau^2 + \beta_3(t)\tau^3$$

kde  $\tau = -m, \dots, 0, \dots, m$  podle uvažované délky klouzavých průměrů.

# Metoda klouzavých vážených průměrů

Koeficienty  $\beta_0, \beta_1, \beta_2, \beta_3$  se hledají obdobně jako u lineárního trendu, tedy pomocí metody nejmenších čtverců.

Minimalizujeme

$$\sum_{\tau=-m}^m (Y_{t+\tau} - \beta_0 - \beta_1\tau - \beta_2\tau^2 - \beta_3\tau^3)^2$$

Parciálními derivacemi podle jednotlivých koeficientů získáme soustavu čtyř rovnic

$$\sum_{\tau=-m}^m Y_{t+\tau}\tau^j - b_0 \sum_{\tau=-m}^m \tau^j - b_1 \sum_{\tau=-m}^m \tau^{j+1} - b_2 \sum_{\tau=-m}^m \tau^{j+2} - b_3 \sum_{\tau=-m}^m \tau^{j+3} = 0$$

pro  $j = 0, 1, 2, 3$ . Hodnotu pro vyhlazení řady v čase  $t$ , tedy  $\hat{Y}_t$ , získáme jako odhad koeficientu  $b_0$ .

# Vlastnosti odhadu $\hat{Y}_t$

- vážený klouzavý průměr hodnot  $Y_{t+\tau}$ , kde  $\tau = -m, \dots, 0, \dots, m$
- součet vah klouzavého průměru je roven jedné
- váhy jsou symetrické kolem střední hodnoty
- je-li  $r$  sudé číslo, pak klouzavé průměry řádu  $r$  a  $r + 1$  se stejnou délkou jsou totožné
- takto vyhlazují hodnoty řady od času  $m$  do  $n = m$ , kde  $n$  je délka řady (tedy prvních  $m$  a posledních  $m$  hodnot řady zůstává nevyhlazeno)

# Váhy pro klouzavé průměry

Tabulka vah klouzavých průměrů pro různé délky a řády vyhlazení


Délka	Řád 2 a 3	Řád 4 a 5
3	(0,1,0)	(0,1,0)
5	$\frac{1}{35}(-3, 12, 17, \dots)$	(0,0,1,...)
7	$\frac{1}{21}(-2, 3, 6, 7, \dots)$	$\frac{1}{231}(5, -30, 75, 131, \dots)$
9	$\frac{1}{231}(-21, 14, 39, 54, 59, \dots)$	$\frac{1}{429}(15, -55, 135, 179, \dots)$
11	$\frac{1}{429}(-36, 9, 44, 69, 84, 89, \dots)$	$\frac{1}{429}(18, -45, -10, 60, 120, 143, \dots)$



# Metoda klouzavých průměrů

## Různé délky a řády klouzavých průměrů

### Vyvoj plodnosti v CR



# Vyhlazení krajních hodnot

- "středové" hodnoty řady se vyhlazují pomocí sousedních hodnot na obě strany od daného času
- krajní hodnoty se vyhlazují pomocí krajních  $2m + 1$  hodnot
- vyhlazuje se pomocí odhadovaného polynomiálního trendu
- jsou potřeba i ostatní koeficienty (nejen  $b_0$ , ale i např.  $b_1, b_2, b_3$ )
- ve výsledku pak dostaneme jen jiné váhy krajních  $2m + 1$  hodnot, které již nejsou symetrické
- obdobně lze počítat i predikce – každá další předpovídaná hodnota vyžaduje jiné váhy posledních  $2m + 1$  hodnot řady

# Volba řádu klouzavých průměrů

- **Objektivní pravidlo** je založené a diferencích
  - každá diference sníží řád původního polynomu o 1
  - pokud se  $r$ -tá diference jako první jeví konstantně, pak volím řád klouzavých průměrů  $r$
- **Subjektivní pravidlo**
  - preference jednoduchého řešení, tj. klouzavé průměry co nejnižšího řádu
- **Praktické pravidlo**
  - v praxi se jiný než lineární řád nepoužívá
  - nejčastěji se používají nevážené klouzavé průměry nebo váhy, které odpovídají subjektivní důležitosti okolních hodnot
  - časté jsou např. váhy  $\frac{1}{10}(1, 2, 4, 2, 1)$  nebo  $\frac{1}{12}(1, 2, 2, 2, 2, 2, 1)$

# Exponenciální vyrovnání

- Stejně jako metoda klouzavých průměrů, patří i exponenciální vyrovnání mezi **adaptivní přístupy**.
- Hlavní rozdíl oproti klouzavým průměrům je, že pro výpočet vyrovnané hodnoty v čase  $t$  nepoužívám hodnoty na obě strany od času  $t$ , ale pouze hodnoty předcházející času  $t$ .
- Používají se všechny minulé dostupné hodnoty s vahami exponenciálně klesajícími do minulosti.

# Exponenciální vyrovnání

Předpokládejme, že časovou řadu tvoří pouze trend a náhodná složka

$$Y_t = Tr_t + \varepsilon_t$$

Mohu vyrovnávat

- lokálně konstantní trend  $Tr_t = \beta_0$   
jednoduché exponenciální vyrovnávání
- lokálně lineární trend  $Tr_t = \beta_0 + \beta_1 t$   
dvojitě exponenciální vyrovnávání
- lokálně kvadratický trend  $Tr_t = \beta_0 + \beta_1 t + \beta_2 t^2$   
trojitě exponenciální vyrovnávání
- trendy vyššího řádu už se neuvažují

# Exponenciální vyrovnání

## Jednoduché exponenciální vyrovnávání

Odhad vyrovnávací hodnoty  $b_0(t)$  získám minimalizací výrazu

$$\sum_{i=1}^{\infty} (Y_{t-i} - \beta_0)^2 \alpha^i$$

kde  $\alpha$  je vyrovnávací konstanta

- obecně musí platit  $0 < \alpha < 1$
- praxe ukázala, že stačí uvažovat  $0.7 < \alpha < 1$

# Exponenciální vyrovnání

## Jednoduché exponenciální vyrovnávání

Derivací výše uvedeného výrazu podle  $\beta_0$  a položení této derivace rovno nule, získám odhad parametru  $b_0(t)$  a tedy i vyrovnanou hodnotu v čase  $t$ .

$$\hat{Y}_t = (1 - \alpha) \sum_{i=0}^{\infty} \alpha^i Y_{t-i}$$

Získám tedy vážený součet minulých hodnot s vahami

$$(1 - \alpha), (1 - \alpha)\alpha, (1 - \alpha)\alpha^2, \dots$$

exponenciálně klesajícími do minulosti.

Je možné psát i rekurentní vzorec

$$\hat{Y}_t = (1 - \alpha) Y_t + \alpha \hat{Y}_{t-1}$$

# Exponenciální vyrovnání

## Jednoduché exponenciální vyrovnávání

Volba vyrovnávací konstanty  $\alpha$

- čím menší  $\alpha$ , tím tím rychleji metoda reaguje na změnu v řadě
- větší  $\alpha$  zesílí vyrovnávací schopnost metody
- znám-li optimální délku  $M$  klouzavého průměru pro danou řadu, mohou volit
$$\alpha = \frac{M-1}{M+1}$$
- jinak (častěji) volím numericky: spočítám si vyrovnání řady pro různé hodnoty  $\alpha = 0.7, 0.72, \dots, 0.98$ , pro každé ohodnotím, jak vyrovnání souhlasí s mými daty (např. pomocí *SSE – Sum of Squared Errors*) a volím  $\alpha$  s nejnižším *SSE*
- softwary už volí automaticky



# Exponenciální vyrovnání

## Jednoduché exponenciální vyrovnávání

### Předpovědi

- budoucí hodnoty předpovídám poslední vyrovnanou hodnotou  $\hat{Y}_n$
- předpovědní interval spolehlivosti má tvar

$$(\hat{Y}_{n+\tau}(n) - z d_\tau \Delta(n), \hat{Y}_{n+\tau}(n) + z d_\tau \Delta(n))$$

kde  $z$  je příslušný kvantil standartního normálního rozdělení,  $d_t = 1.25$  a

$$\Delta(n) = \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t(t-1)|}{n}$$

- výhodou těchto předpovědí a předpovědních intervalů je jejich snadná úprava, pokud do řady přibude další pozorování

# Exponenciální vyrovnání

## Jednoduché exponenciální vyrovnávání

### Adaptivní řídicí proces

- je možné uvažovat i vyrovnávací konstantu  $\alpha$  měnící se v čase
- definuje se **indikátor poruchy**

$$I(\alpha, t) = \left| \frac{Y(\alpha, t)}{D(\alpha, t)} \right|$$

kde

$$Y(\alpha, t) = \sum_{i=1}^t e_i(\alpha), \quad D(\alpha, t) = \sum_{i=1}^t \frac{|e_i(\alpha)|}{t}$$

a  $e_i$  je chyba předpovědi

- zvedne-li se hodnota  $I(\alpha, t)$  nad kontrolní mez  $K$ , pak je to signál ke změně  $\alpha$  či dokonce celé metody

# Exponenciální vyrovnání

## Dvojitě exponenciální vyrovnávání

Odhad vyrovnávací hodnoty  $b_0(t) + b_1(t)t$  získám minimalizací výrazu

$$\sum_{i=1}^{\infty} (Y_{t-i} - (\beta_0 + \beta_1(-i)))^2 \alpha^i$$

kde  $\alpha$  je opět vyrovnávací konstanta a platí pro ni to, co u jednoduchého exponenciálního vyrovnání

- obecně musí platit  $0 < \alpha < 1$
- praxe ukázala, že stačí uvažovat  $0.7 < \alpha < 1$
- jen optimální volba při znalosti optimální délky klouzavého průměru  $M$  je  $\alpha = \sqrt{\frac{M-1}{M+1}}$

# Exponenciální vyrovnání

## Trojité exponenciální vyrovnávání

V praxi se využívá minimálně, ale "ještě to jde". Odhad vyrovnávací hodnoty  $b_0(t) + b_1(t)t + b_2(t)t^2$  získám minimalizací výrazu

$$\sum_{i=1}^{\infty} (Y_{t-i} - (\beta_0 + \beta_1(-i) + \beta_2(-i)^2))^2 \alpha^i$$


pro vyrovnávací konstantu  $\alpha$  opět platí

- obecně musí platit  $0 < \alpha < 1$
- praxe ukázala, že stačí uvažovat  $0.7 < \alpha < 1$
- ale používá se trochu jiná počáteční volba hodnot při hledání optimálního  $\alpha$

# Exponenciální vyrovnání

## Grafická ukázka

### Holt-Winters filtering



# Holt-Wintersova metoda

Máme-li sezónní data, je možné odhadovat jejich chování

## **Holt-Wintersovu metodu**

- zobecnění metody exponenciálního vyrovnání
- adaptivní metoda
- odhaduje sezónní složku, nevyhlazuje ji
- metoda je aplikovatelná jak na aditivní, tak na multiplikativní model

Předpokládejme lokálně lineární trend

$$Tr_t(t) = \beta_0(t) + \beta_1(t)t$$

a sezónní složku  $s_t(t)$ . Označme  $a_0(t) = b_0(t) + b_1(t)$ , kde  $b_0(t)$  a  $b_1(t)$  jsou odhady regresních koeficientů lokálně lineárního trendu a  $L$  počet sezón.

# Holt-Wintersova metoda

## Aditivní Holt-Wintersova metoda

Výše uvedené odhady se řídí následujícími vztahy

$$a_0(t) = \alpha(Y_t - s_{t-L}(t-L)) + (1 - \alpha)(a_0(t-1) + b_1(t-1))$$

$$b_1(t) = \beta(a_0(t) - a_0(t-1)) + (1 - \beta)b_1(t-1)$$

$$s_t(t) = \gamma(Y_t - a_0(t)) + (1 - \gamma)s_{t-L}(t-L)$$

Odhad hodnoty  $Y_{t+\tau}$  pak můžeme počítat jako

$$\hat{Y}_{t+\tau}(t) = a_0(t) + b_1(t)\tau + s_{t+\tau-L}(t + \tau - L)$$

- za  $s_{t+\tau-L}(t + \tau - L)$  používáme nejaktuálnější odhad sezónní složky, který máme k dispozici
- za počáteční hodnoty  $a_0, b_1$  bereme odhady regresních koeficientů ze všech dat
- za počáteční odhad sezónní složky bereme průměr dané sezóny proti průměru všech dat

# Holt-Wintersova metoda

## Multiplikativní Holt-Wintersova metoda

Výše uvedené odhady se řídí následujícími vztahy

$$a_0(t) = \alpha \left( \frac{Y_t}{s_{t-L}(t-L)} \right) + (1 - \alpha)(a_0(t-1) + b_1(t-1))$$

$$b_1(t) = \beta(a_0(t) - a_0(t-1)) + (1 - \beta)b_1(t-1)$$

$$s_t(t) = \gamma \left( \frac{Y_t}{a_0(t)} \right) + (1 - \gamma)s_{t-L}(t-L)$$

Odhad hodnoty  $Y_{t+\tau}$  pak můžeme počítat jako


$$\hat{Y}_{t+\tau}(t) = (a_0(t) + b_1(t)\tau)s_{t+\tau-L}(t + \tau - L)$$




# Holt-Wintersova metoda

Porovnání exponenciálního vyrovnání a Holt-Wintersovy metody

Dvojite exponencialni vyrovnani



Holt-Wintersova metoda



# Náhodná složka

Předpokládáme, že náhodná složka je tvořena tzv. **bílým šumem**.

## Definition

Nezávislé, stejně rozdělené náhodně veličiny s nulovou střední hodnotou a konstantním rozptylem.

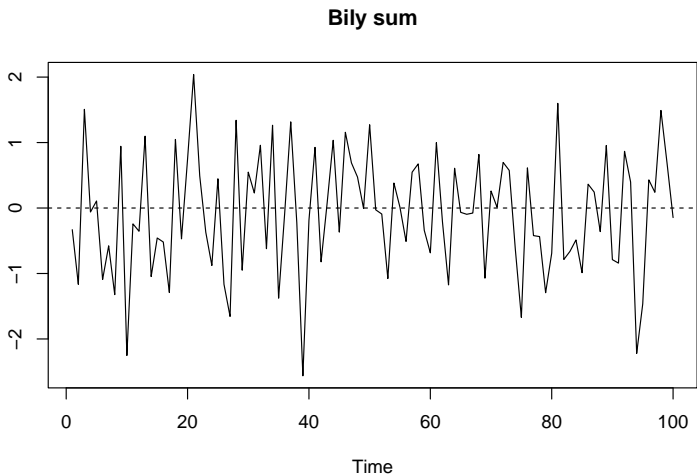
U náhodné složky je často třeba zjistit, zda je skutečně náhodná. Rozlišujeme dva případy

- máme časovou řadu, která na první pohled vypadá jako bílý šum
- máme časovou řadu, kde jsme odstínili trend a sezónní složku a o zbytku potřebujeme rozhodnout, zda tvoří bílý šum

V každém z případů se používají jiné testy náhodnosti.

# Náhodná složka

## Bílý šum



# Náhodná složka

## Testy náhodnosti pro řadu, co vypadá jako býlý šum

Testuje se  $H_0$  : řada je náhodná vs.  $H_1$  : řada není nahodná

- Test založený na **znaménkách diferencí**  
spočítám, v kolika bodech řada roste,  
je-li řada náhodná, mělo by to být cca v jedné polovině případů
- Test založený na **Kendallově koeficientu**  $\tau$   
Kendallův korelační koeficient pro řadu  $Y_t$  a indexy pozorování  $t$

$$\tau = \frac{4v}{n(n-1)} - 1$$

kde  $v$  je počet případů, kde  $Y_t > Y_s$  pro  $t > s$

# Náhodná složka

## Testy náhodnosti pro řadu, co vypadá jako býlý šum

- Test založený na **Spearmanově koeficientu**  $\rho$   
Spearmanův korelační koeficient pro řadu  $Y_t$  a indexy pozorování  $t$

$$\rho = 1 - \frac{6}{n(n^2 - 1)} \sum_{t=1}^n (t - r_t)^2$$

kde  $r_t$  je pořadí  $t$ -té hodnoty  $Y_t$

- **Wald-Wolfowitz Runs Test** (nebo též mediánový test)  
založen na hodnocení, zda je číslo nad(+)/pod(-)  
mediánem a počítá se, kolik úseků stejného znaménka v  
řadě máme

# Náhodná složka

## Testy náhodnosti pro residuální složku

Testuje se:  $H_0$  : autokorelace je nulová vs.  $H_1$  : autokorelace není nulová

- **Ljung-Box** neboli **Box-Pierce** test náhodnosti testuje velikost autokorelace v určených bodech

$$Q = n(n+2) \sum_{\tau=1}^h \frac{r_{\tau}^2}{n-\tau}$$

kde  $r_{\tau}$  je odhad autokorelace v čase  $\tau$  (tedy korelace hodnot posunutých o  $\tau$  kroků)



# Box-Jenkinsonova metodologie

Pro vysvětlení Box-Jenkinsonova metodologie analýzy časových řad definujeme následující pojmy

- **stacionarita** – znamená *stálost* časové řady
- **striktní stacionarita** – všechny členy řady mají stejné rozdělení
- **slabá stacionarita** – všechny členy řady mají stejnou (předpokládejme že nulovou) střední hodnotu a stejný rozptyl  $\sigma_y^2$

Základy modely budeme definovat pro stacionární (stačí slabě) časové řady.

# Box-Jenkinsonova metodologie

Analýza těchto řad je založena na vzájemných vztazích mezi členy řady

- **autokovarianční funkce** – je to funkce vzdálenosti mezi dvěma členy řady

$$\gamma_k = \text{cov}(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu)$$

kde  $\mu$  je střední hodnota členů řady

- **autokorelační funkce**

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\gamma_k}{\sigma_y^2}$$



# Box-Jenkinsonova metodologie

- **parciální autokorelační funkce** – jedná se o parciální korelační koeficient řad  $Y_t$  a  $Y_{t+k}$  při pevných hodnotách  $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$

$$\rho_{kk} = \frac{|\mathbf{P}_k^*|}{|\mathbf{P}_k|}$$

kde

$$\mathbf{P}_k = \begin{bmatrix} 1 & \rho_1 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \dots & \rho_{k-1} \\ \dots & \dots & \dots & \dots \\ \rho_{k-1} & \rho_{k-2} & \dots & 1 \end{bmatrix} \quad \mathbf{P}_k^* = \begin{bmatrix} 1 & \rho_1 & \dots & \rho_1 \\ \rho_1 & 1 & \dots & \rho_2 \\ \dots & \dots & \dots & \dots \\ \rho_{k-1} & \rho_{k-2} & \dots & \rho_k \end{bmatrix}$$

# Box-Jenkinsova metodologie

Odhad autokorelační funkce a jeho vlastnosti.

- odhad střední hodnoty  $\bar{Y} = \sum_{i=1}^n \frac{Y_t}{n}$
- odhad rozptylu řady  $s_y^2 = c_0 = \sum_{t=1}^n \frac{(Y_t - \bar{Y})^2}{n}$
- odhad autokovarianční funkce  $c_k = \sum_{t=1}^{n-k} \frac{(Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{n}$
- odhad autokorelační funkce  $r_k = \frac{c_k}{c_0}$

Tento odhad kovarianční funkce a tedy ani autokorelační funkce není nestranný (to by se muselo dělit  $n - k$ ), ale má malou střední chybu ( $E(c_k - \gamma_k)^2$ ). Výše uvedený odhad je asymptoticky nestranný.

# Box-Jenkinsova metodologie

Někdy je třeba otestovat, od kterého bodu se autokorelační funkce dá považovat za nevýznamnou. K tomu se používá **Bartletova aproximace**

$$\sigma(r_k) = \sqrt{\text{Var}(r_k)} \sim \sqrt{\frac{1}{n} \left( 1 + 2 \sum_{j=1}^{k_0} r_j^2 \right)}$$

pro  $k > k_0$ . Pro zjednodušení se porovnává odhadovaná hodnota autokorelační funkce  $|r_k|$  s číslem  $2\sigma$ .

# Box-Jenkinsova metodologie

Parciální autokorelační funkce se odhaduje rekurentně na základě následujících pravidel

- $r_{11} = r_1$
- $r_{kk} = \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j}$
- kde  $r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-j}$

Test o nulovosti parciální autokorelační funkce je založen na **Quenouilleově aproximaci**

$$\sigma(r_{kk}) \sim \sqrt{\frac{1}{n}}$$

pro  $k > k_0$ . Pro jednoduchost se opět odhad parciální autokorelační funkce porovnává s hodnotou  $2\sigma(r_{kk})$

# Box-Jenkinsova metodologie

## Lineární proces

Lineárním procesem nazýváme řadu tvaru

$$Y_t = \varepsilon_t + \psi_1 \varepsilon_{t-1} + \psi_2 \varepsilon_{t-2} + \dots$$

kde  $\varepsilon_t$  je bílý šum s rozptylem  $\sigma_\varepsilon^2$  a  $\psi_j$  jsou parametry. Zavedme operátor zpětného posunutí  $B$  následovně

$$BY_t = Y_{t-1}, \quad B^j Y_t = Y_{t-j}$$

Jeho pomocí je možné zapsat lineární proces jako

$$Y_t = \psi(B)\varepsilon_t$$

kde

$$\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots = 1 + \sum_{j=1}^{\infty} \psi_j B^j$$

# Box-Jenkinsova metodologie

Pomocí operátoru zpětného posunu nastavíme podmínky na časové řady, aby byly popsateľné modely Box-Jenkinsovy metodologie.

Řada  $\psi(B)$  konverguje pro  $|B| \leq 1$ , uvažujeme-li  $B$  jako číselnou proměnnou. Tato podmínka zároveň zaručí, že lineární proces je stacionární se střední hodnotou nula. Za určitých podmínek lze proces napsat jako

$$Y_t = \pi_1 Y_{t-1} + \pi_2 Y_{t-2} + \dots + \varepsilon_t$$

Pak se lineární proces nazývá invertibilní.

# Box-Jenkinsova metodologie

**Proces klouzavých součtů** (Moving Averages).

Proces klouzavých součtů řádu  $q$  se značí  $MA(q)$  a má tvar

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

který se možné zapsat jako  $Y_t = \theta(B)\varepsilon_t$ , kde

$\theta(B) = 1 + \sum_{j=1}^q \theta_j B^j$  je tzv. **operátor klouzavých součtů**.

Proces  $MA(q)$  je

- stacionární pro libovolné  $\theta_j$
- má nulovou střední hodnotu
- jeho rozptyl je  $\sigma_y^2 = \gamma_0 = (1 + \theta_1^2 + \theta_2^2 + \cdots + \theta_q^2)\sigma_\varepsilon^2$

# Box-Jenkinsova metodologie

## Proces klouzavých součtů (Moving Averages).

- jeho autokorelační funkce je

$$\rho_k = \frac{\theta_k + \theta_1\theta_{k+1} + \cdots + \theta_{q-k}\theta_q}{1 + \theta_1^2 + \theta_2^2 + \cdots + \theta_q^2}$$

pro  $k = 1, \dots, q$  a je  $\rho_k = 0$  pro  $k > q$

- autokorelační funkce má bod useknutí  $k_0 = q$
- parciální autokorelační funkce nemá bod useknutí a je omezena geometricky klesající posloupností nebo sinusoidou s geometricky klesající amplitudou
- proces je invertibilní, pokud všechny kořeny polynomu  $\theta(B)$  leží vně jednotkového kruhu



# Box-Jenkinsova metodologie

## Proces MA(1)

Nejjednodušším procesem klouzavých součtů je proces  $MA(1)$ .

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1}$$

s vlastnostmi

- proces  $MA(1)$  je invertibilní, pokud  $|\theta_1| < 1$   
pak lze tento proces napsat jako

$$Y_t = \theta_1 Y_{t-1} - \theta_1^2 Y_{t-2} + \theta_1^3 Y_{t-3} - \dots + \varepsilon_t$$

- autokorelační funkce

$$\rho_1 = \frac{\theta_1}{1 + \theta_1^2}$$

a  $\rho_k = 0$  pro  $k > 1$

- pro libovolný proces  $MA(1)$  musí být  $|\rho_1| < \frac{1}{2}$

# Box-Jenkinsova metodologie

## Proces MA(1)

- parametr  $\theta_1$  lze spočítat z autokorelace  $\rho_1$

$$\theta_1 = \frac{1 - \sqrt{1 - 4\rho_1^2}}{2\rho_1}$$

a pouze jeden z kořenů splňuje podmínku invertibility

- parciální autokorelační funkce je

$$\rho_{kk} = \frac{(-1)^{k-1} \theta_1^k (1 - \theta_1^2)}{1 - \theta_1^{2(k+1)}}$$

- platí  $|\rho_{kk}| < |\theta_1|^k$

# Box-Jenkinsova metodologie

**Autoregresní proces** (Autoregressive process)

**Autoregresní proces** řádu  $p$  se značí  $AR(p)$  a má tvar

$$Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$$

tento proces můžeme pomocí zpětného operátoru zapsat jako

$$\varphi(B)Y_t = \varepsilon_t$$

kde  $\varphi(B) = 1 - \sum_{j=1}^p \varphi_j B^j$  je tzv. **autoregresní operátor**.

- proces  $AR(p)$  je automaticky invertibilní
- proces  $AR(p)$  je stacionární, pokud všechny kořeny polynomu  $\varphi(B)$  leží vně jednotkového kruhu
- střední hodnota  $AR(p)$  je nulová

# Box-Jenkinsova metodologie

## Autoregresní proces (Autoregressive process)

- pro jeho autokorelační funkci platí

$$\rho_k = \varphi_1 \rho_{k-1} + \varphi_2 \rho_{k-2} + \dots + \varphi_p \rho_{k-p}$$

pro  $k > 0$ .

- autokorelační funkce je lineární kombinací klesajících geometrických posloupností a sinusoid s geometricky klesajícími amplitudami
- parametry  $\varphi_1, \dots, \varphi_p$  je možné z autokorelační funkce dopočítat pomocí **Yule-Walkerových rovnic**
- rozptyl

$$\sigma_y^2 = \gamma_0 = \frac{\sigma_\varepsilon^2}{1 - \varphi_1 \rho_1 - \dots - \varphi_p \rho_p}$$

- parciální autokorelační funkce má bod useknutí  $k_0 = p$  a je tedy  $\rho_{kk} = 0$  pro  $k > p$ .

# Box-Jenkinsova metodologie

## Proces AR(1)

Nejjednodušším autoregresním procesem je  $AR(1)$  tvaru

$$Y_t = \varphi_1 Y_{t-1} + \varepsilon_t$$

s vlastnostmi

- $AR(1)$  je stacionární, pokud  $|\varphi_1| < 1$
- autokorelační funkce procesu  $AR(1)$  je

$$\rho_k = \varphi_1^k$$

pro  $k > 0$  a je to tedy geometrická posloupnost klesající k nule

- pro  $k = 1$  máme  $\rho_1 = \varphi_1$
- parciální autokorelační funkce procesu  $AR(1)$  je

$$\rho_{11} = \rho_1 = \varphi_1, \quad \rho_{kk} = 0$$

pro  $k > 1$ , tedy parciální autokorelační funkce má bod useknutí  
 $k_0 = 1$

# Box-Jenkinsova metodologie

## Smíšený proces

Smíšený proces z částí *MA* řádu  $q$  a *AR* řádu  $p$  nazýváme *ARMA* řádu  $p$  a  $q$  a má tvar

$$Y_t = \varphi_1 Y_{t-1} + \cdots + \varphi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

Pomocí operátoru zpětného posunutí je zápis jednodušší

$$\varphi(B)Y_t = \theta(B)\varepsilon_t$$

Vlastnosti procesu *ARMA*( $p, q$ )

- podmínka stacionarity je stejná jako u *AR*( $p$ )
- podmínka invertibility je stejná jako u *MA*( $q$ )
- kořeny polynomů  $\theta(B)$  a  $\varphi(B)$  musí ležet vně jednotkového kruhu

# Box-Jenkinsova metodologie

## Smíšený proces

- střední hodnota  $ARMA(p, q)$  je nulová
- pro autokorelační funkci  $\rho_k$  platí

$$\rho_k = \varphi_1 \rho_{k-1} + \varphi_2 \rho_{k-2} + \cdots + \varphi_p \rho_{k-p}$$

pro  $k > q$

- je-li  $q \geq p$  pak od času  $q - p + 1$  je autokorelační funkce tvořena geometricky klesající posloupností, nebo kombinací sinusoid s geometricky klesajícími amplitudami
- parciální autokorelační funkce  $\rho_{kk}$  je obdobně od času  $p - q + 1$  omezena geometricky klesající posloupností nebo sinusoidou s geometricky klesající amplitudou

# Box-Jenkinsova metodologie

## Proces ARMA(1,1)

Proces ARMA(1, 1) má tvar

$$Y_t = \varphi_1 Y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}$$

s vlastnostmi

- podmínka stacionarity  $|\varphi_1| < 1$
- podmínka invertibility  $|\theta_1| < 1$
- rozptyl řady je

$$\sigma_y^2 = \gamma_0 = \frac{1 + \theta_1^2 + 2\varphi_1\theta_1}{1 - \varphi_1^2} \sigma_\varepsilon^2$$

- pro autokorelační funkci platí  $\rho_k = \varphi_1 \rho_{k-1}$  pro  $k > 1$
- autokorelační funkce v čase 1 je

$$\rho_1 = \frac{(1 + \varphi_1\theta_1)(\varphi_1 + \theta_1)}{1 + \theta_1^2 + 2\varphi_1\theta_1} 1 - \varphi_1^2$$



# Box-Jenkinsova metodologie

## Proces ARMA(1,1)

- parametry pak můžeme odhadnout pomocí

$$\varphi_1 = \frac{\rho_2}{\rho_1}, \quad \theta_1 = \frac{b \pm \sqrt{b^2 - 4}}{2}$$

kde

$$b = \frac{1 - 2\rho_2 + \varphi_1^2}{\rho_1 - \varphi_1}$$

a jen jeden kořen odpovídá podmínce invertibility

- pro autokorelační funkci musí dále platit

$$2\rho_1^2 - |\rho_1| < \rho_2 < |\rho_1|$$

- parciální autokorelační funkce je omezena geometricky klesající posloupností

# Box-Jenkinsova metodologie

Jak najít optimální model pro stacionární řadu

první nápovědu dají autokorelační a parciální autokorelační funkce

	$\rho_k$	$\rho_{kk}$
$AR(p)$	neexistuje bod useknutí	bod useknutí $k_0 = p$
$MA(q)$	bod useknutí $k_0 = q$	neexistuje bod useknutí
$ARMA(p, q)$	neexistuje bod useknutí po $q - p$ hodnotách omezena	neexistuje bod useknutí po $p - q$ hodnotách omezena

# Box-Jenkinsova metodologie

## Odhad parametrů modelu

- používá se metoda nejmenších čtverců (minimalituje se součet  $\sum_{t=1}^n (\varepsilon_t(\varphi, \theta))^2$ )
- jelikož funkce  $\varepsilon_t$  je v parametrech  $\varphi$  a  $\theta$  nelineární, jedná se o nelineární součet čtverců a je třeba postupovat iterativně
- počítač necháme odhadnout několik základních modelů (většinou některé z  $AR(1)$ ,  $AR(2)$ ,  $AR(3)$ ,  $MA(1)$ ,  $MA(2)$ ,  $MA(3)$ ,  $ARMA(1, 1)$ ,  $ARMA(2, 1)$ ,  $ARMA(1, 2)$ ,  $ARMA(2, 2)$ )
- pomocí určitého kritéria zvolíme optimální model
- porovnáme volbu s průběhem autokorelační a parciální autokorelační funkce

# Box-Jenkinsova metodologie

## Kritéria pro výběr modelu

- Akaikeho informační kritérium

$$AIC = \ln \hat{\sigma}_\varepsilon^2 + 2 \frac{k}{n}$$

kde  $k$  je počet parametrů modelu  
nejznámější kritérium, které však upřednostňuje modely s vyšším počtem parametrů

- Bayesovské informační kritérium

$$BIC = \ln \hat{\sigma}_\varepsilon^2 + \frac{k \ln n}{n}$$

toto kritérium je nejvhodnější pro optimální volbu modelu

- Hannan-Quinn informační kritérium

$$HQ = \ln \hat{\sigma}_\varepsilon^2 + c \frac{k \ln \ln n}{n}$$

nejčastěji se volí  $c = 1$   
kritérium vymyšleno přímo pro B-J modely

Čím menší hodnota kritéria, tím lepší model.

# Box-Jenkinsova metodologie

## Ověření vybraného modelu

- střední chyba odhadnutých parametrů by měla být víc jak dvakrát menší než absolutní hodnota samotného odhadu
- odhadnutý rozptyl bílého šumu by neměl být příliš velký
- residua odhadnutého modelu by měla být nezávislá, jejich autokorelační funkce by tedy měla nabývat malých hodnot např. pro  $AR(1)$  by  $r_1(\varepsilon)$  měla být menší než  $2\varphi_1^2/n$
- máme i test na hodnoty autokorelační funkce residuí (Ljung-Box test)

# Box-Jenkinsova metodologie

## Integrované ARMA modely

- tyto modely nevyžadují stacionaritu - umí si poradit s trendem
- odstínění trendu se zde realizuje přes difference
- počet nutných diferencí před odhadem ARMA modelu odpovídá komplikovanosti trendu
- většinou stačí diferencovat jednou, maximálně dvakrát

Integrovaný ARMA model se značí  $ARIMA(p, d, q)$ , kde

- $p$  je řád autoregrese
- $q$  je řád klouzavých průměrů
- $d$  je nutný počet diferencí potřebný se stacionarizací původní řady

# Box-Jenkinsova metodologie

## Model ARIMA(p,d,q)

Model zapisujeme jako

$$\varphi(B)w_t = \theta(B)\varepsilon_t$$

kde  $w_t = \Delta^d Y_t$  je  $d$ -tá diference modelu a platí

$$\Delta Y_t = Y_t - Y_{t-1} = (1 - B)Y_t$$

$$\Delta^2 Y_t = (1 - B)^2 Y_t = (1 - 2B + B^2)Y_t = Y_t - 2Y_{t-1} + Y_{t-2}$$

Model  $ARIMA(p, d, q)$  pak můžeme zapsat jako

$$\varphi(B)(1 - B)^d Y_t = \theta(B)\varepsilon_t$$

Nevýhodou je, že řada diferencí má o  $d$  prvků méně než původní řada, kde  $d$  je řád difference

# Box-Jenkinsova metodologie

## Určení řádu difference pro procesy ARIMA

- využití "okometrické metody"  
diferencuji tak dlouho, až mi výsledná řada diferencí přijde jako stacionární
- s pomocí autokorelační funkce  
jestliže hodnoty autokorelační funkce diferencí klesají pomalu (přibližně lineárně a ne geometricky), diferencuji dál
- pomocí odhadu rozptylu řady diferencí  
vyberu tu diferenci, která má minimální odhad rozptylu řady
- pomocí počítače  
použiji nejnižší diferenci, pro niž mi počítač umí ARIMA model odhadnout



# Box-Jenkinsova metodologie

## Sezónní integrovaný ARMA model

I se sezónními řadami si umí BJ metodologie poradit. Řešením jsou tzv. **SARIMA modely**.

Myšlenka konstrukce těchto modelů

- pro každou sezónu (např. leden) se zkonstruuje samostatný model  $ARIMA(P, D, Q)$
- modely pro jednotlivé sezóny by měly být přibližně stejné
- náhodné složky v těchto modelech  $\eta_t$  by měly být vzájemně korelované
- pro tyto náhodné složky zkonstruujeme další model  $ARIMA(p, d, q)$
- spojením těchto modelů dostaneme

$$\varphi(B)\Phi(B^s)\Delta^d\Delta_s^D Y_t = \theta(B)\Theta(B^s)\varepsilon_t$$

kde  $s$  je počet sezón (pro měsíční data 12, pro čtvrtletní 4, atd.).

Výsledkem je tzv. **multiplikativní sezónní model řádu**

# Box-Jenkinsova metodologie

## Identifikace modelu

- stěžejní je určení řádu diferencí
- diferencuje se přes délku sezóny i přes sousední hodnoty
- určení řádu difference záleží na autokorelační funkci
- pokud má autokorelační funkce vysokou hodnotu v délce sezóny, je nutné diferencovat přes sezónu
- pokud má autokorelační funkce pomalu klesající hodnoty, je třeba diferencovat přes sousední hodnoty
- je možné volit optimální model i podle minimalizace rozptylu řady

# Box-Jenkinsova metodologie

## Předpovědi

- předpovědi konstruujeme rekurentně
- namísto aktuálních hodnot bílého šumu bereme nulu, za starší hodnoty bílého šumu bereme chyby předchozích předpovědí
- předpovědní interval spolehlivosti

$$\hat{Y}_{t+k}(t) \pm 2\sigma\{e_{t+k}(t)\}$$

kde  $e_t(t-1) = Y_t - \hat{Y}_t(t-1)$ .

# Závislost časových řad

Nejjednodušším způsobem, jak zkoumat závislost mezi dvěma časovými řadami je použít **kroskorelační funkci** definovanou jako

$$\rho_k^c = \frac{\text{cov}(Y_t, X_{t+k})}{\sigma_y \sigma_x}$$

- v porovnání s běžným korelačním koeficientem uvažujeme i korelaci se zpožděním
- odhad této funkce je

$$r_k^c = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(X_{t+k} - \bar{X})}{\sqrt{\sum_{t=1}^n (Y_t - \bar{Y})^2} \sqrt{\sum_{t=1}^n (X_t - \bar{X})^2}}$$

- jako hrubý odhad střední chyby odhadu  $r_k^c$  můžeme uvažovat (obdobně jako u autokorelační funkce)

$$\sigma(r_k^c) = \sqrt{\text{Var}(r_k^c)} \sim \sqrt{\frac{1}{n} \left( 1 + 2 \sum_{j=1}^{k_0} (r_j^c)^2 \right)}$$

# Závislost časových řad

Je možné uvažovat i regresní závislost mezi časovými řadami. Jedná se o tzv. **lineární dynamické modely**

- do těchto modelů vstupují jako regresory jak předcházející hodnoty vlastní řady, tak současné, případně zpožděné hodnoty řad jiných
- optimální zpoždění, s jakým budeme modelovat závislost řady  $Y_t$  na řadě  $X_t$  odhadneme např. z kroskorelační funkce
- modely se většinou odhadují pomocí běžné metody nejmenších čtverců
- správný model je ten, jehož residua mají nulovou autokorelační funkci pro  $k > 0$