

ANALÝZA ČASOVÝCH ŘAD

Radka Vokřálová

Ústav matematiky a statistiky
Masarykova univerzita, Brno

Seminář z finanční matematiky

Obsah

- 1 Náhodné procesy
 - Časové řady
 - Popis časových řad
- 2 Klasická dekompozice časových řad
 - Modelování trendu
- 3 Box-Jenkinsonova metodologie
 - Odhady v *ARMA* procesech
 - Autokorelační funkce
- 4 Spektrální analýza časových řad
 - Spektrální hustota
 - Odhady spektrální hustoty

Náhodné procesy

- Náhodný proces je reálnou funkcí dvou proměnných – elementárního jevu a jedné reálné proměnné, kterou obvykle bývá čas. Značení $\{Y(\omega, t), \omega \in \Omega, t \in T\}$ a zkráceně $\{Y_t, t \in T\}$.
- Náhodný proces, kde indexová množina $T = \mathbb{Z}$ nebo je $T \subset \mathbb{Z}$, se nazývá proces s diskrétním časem nebo náhodná posloupnost nebo také **časová řada**.
- Příklady náhodných procesů v ekonomice
 - Změny poptávky po určitém výrobku
 - Analýza vývoje kurzu akcií na burze
 - Objem zemědělské produkce

Popis časových řad

- Časové řady lze popsat pomocí tzv. aditivního modelu:

$$Y_t = Tr_t + Sz_t + \varepsilon_t \quad (1)$$

nebo multiplikativního modelu: $Y_t = Tr_t \cdot Sz_t \cdot \varepsilon_t$, který se ovšem může logaritmováním transformovat na aditivní model.

- Jednotlivé složky jsou
 - Tr_t – trend, který odráží dlouhodobé působení vlivů
 - Sz_t – sezónní složka, která popisuje periodické změny, např. vliv ročních období
 - ε_t – náhodné fluktuace (kolísání), které modeluje vlivy, které působí nepravidelně

I. Klasická dekompozice časových řad

- Mezi základní přístupy analýzy časových řad patří klasická dekompozice, která je založena na regresní analýze. Vychází z předpokladu, že náhodný proces, který generuje časovou řadu, je **závislý pouze na čase**.
- Jednotlivá pozorování se obvykle považují za navzájem **nekorelovaná**, tj. $\{\varepsilon_t, t \in \mathbb{Z}\}$ se chápe jako **bílý šum** s nulovou střední hodnotou a varianční maticí $(C(\varepsilon_i, \varepsilon_j))_{i,j=1}^n = \sigma^2 \mathbf{I}_n$.
- Dekompozicí rozumíme rozklad na **deterministickou** a **stochastickou** (náhodnou) složku, kde deterministickou složku ještě dále rozkládáme na sezónní složku a trend.

I. Klasická dekompozice časových řad

MODELOVÁNÍ TRENDU

- Trend v časové řadě představuje tendenci dlouhodobého vývoje sledovaného ukazatele v čase. V rámci ekonomického využití časových řad je trend nejdůležitější složkou, která nás zajímá jak z hlediska současného stavu, tak i **predikce budoucího vývoje**.
- Klasická dekompozice trend modeluje pomocí regresních modelů, kde se do trendu obvykle zahrnují i cyklické složky s periodou.
- Ke stanovení trendů lze v závislosti na typu a charakteru náhodného kolísání použít dva různé přístupy:
 - 1 **Parametrický přístup**, který předpokládá určitý typ rozdělení, obvykle pak normální rozdělení bílého šumu
 - 2 **Neparametrický přístup**, kam patří různé metody založené na jádrových odhadech

I. Klasická dekompozice časových řad

MODELY GLOBÁLNÍHO TRENDU

- Regresní modely dále můžeme rozdělit na modely globálního trendu a modely postupného lokálního trendu.
- U modelů **globálního trendu**, uvažujeme časovou řadu $\{Y_t, t \in T\}$ a n pozorování této řady v časových okamžicích $t_1 < t_2 < \dots < t_n$. Předpokládáme, že jednotlivá pozorování v čase t_i vyhovují modelu

$$Y_{t_i} = f(t_i) + \varepsilon_i, \quad i = 1, \dots, n \quad (2)$$

kde $f(t_i)$ je neznámá **trendová funkce** vybraná z předem dané třídy funkcí, tj. jedná se o parametrický přístup.

MODELY GLOBÁLNÍHO TRENDU

Regresní model trendu

- Předpokládáme, že trendová funkce je určena konečným počtem parametrů

$$f(t) = \beta_0 + \beta_1\varphi_1(t) + \cdots + \beta_p\varphi_p(t), \quad (3)$$

kde $\beta_0, \beta_1, \dots, \beta_p$ jsou neznámé parametry a $\varphi_1(t), \dots, \varphi_p(t)$ jsou známé funkce.

- Takto nám vznikne lineární regresní model tvaru

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

kde matice plánu $\mathbf{X} = ((\varphi_j(t_i))_{i=1, \dots, n, j=0, \dots, p})$ je plně hodnosti, tj. $h(\mathbf{X}) = p + 1$, funkce $\varphi_0 \equiv 1$.

- Neznámé parametry $\boldsymbol{\beta}$ odhadneme pomocí metody nejmenších čtverců (MNČ), kde platí

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \quad (4)$$

MODELY GLOBÁLNÍHO TRENDU

Regresní model trendu

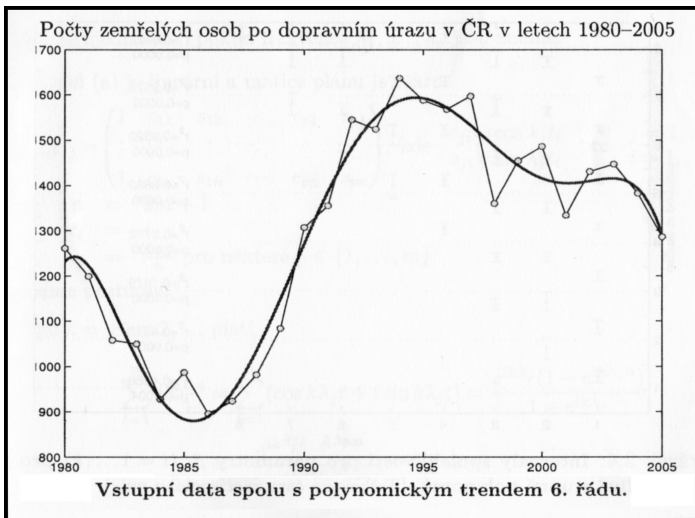
- Příkladem trendové funkce, která vede na lineární regresní model, je tzv. **polynomický trend**

$$f(t) = \beta_0 + \beta_1 t + \dots + \beta_p t^p \quad (5)$$

kde kromě neznámých parametrů β musíme ještě určit vhodný stupeň polynomu p .

- Pro odhad stupně polynomu můžeme využít různé metody. Například metodu „od nejnižšího stupně k nejvyššímu“, penalizační metodu nebo Akaikeovo informační kritérium. Viz. [1, str. 66]

Ukázka časové řady



I. Klasická dekompozice časových řad

MODELY LOKÁLNÍHO POSTUPNÉHO TRENDU

- Hlavní myšlenka **lokální metody** nejmenších čtverců spočívá v tom, že provedeme odhad trendu Tr_t polynomem na lokálním intervalu

$$\langle t - s, t + s \rangle$$

na rozdíl od klasické metody, kdy trend odhadujeme polynomem na celém intervalu možných hodnot parametru t .

- Parametr $s > 0$ se nazývá **šířka vyhlazovacího okénka** a jeho vhodná volba hraje při odhadu důležitou roli.

I. Klasická dekompozice časových řad

MODELY LOKÁLNÍHO POSTUPNÉHO TRENDU

- Lokální metoda nejmenších čtverců se někdy nazývá **klouzavá polynomická metoda**, protože kolem bodu t , v němž má být trend odhadnut, je umístěno vyhlazovací okénko a odhad trendu se mění (pohybuje) spolu s t .
- Uvnitř intervalu aproximujeme trend polynomem stupně m

$$\varrho(x) = \sum_{j=0}^m \beta_j(t)(x - t)^j \quad (6)$$

a neznámé koeficienty $\beta_j(t)$ odhadujeme metodou nejmenších čtverců (případně váženou MNČ), tyto koeficienty budou pro každé t jiné.

I. Klasická dekompozice časových řad

MODELY LOKÁLNÍHO POSTUPNÉHO TRENDU

- Různé metody, které jsou založené na lokální metodě nejmenších čtverců, jsou například - klouzavé průměry, jednoduché klouzavé průměry, centrované klouzavé průměry
- Dále například **modely exponenciálního vyrovnávání** vychází z lokální **vážené** metody nejmenších čtverců, kde jednotlivým údajům v časové řadě jsou přiřazeny rozdílné váhy, které směrem do minulosti exponenciálně klesají.

II. Box-Jenkinsonova metodologie

- Box-Jenkinsonova metodologie na rozdíl od klasické dekompozice předpokládá, že všechny složky časové řady, tj. trend i cyklická složka, mají **náhodný charakter**. A jejím těžištěm je **korelační analýza**.
- Výhodou této metody je její **flexibilita** a to, že se rychle adaptuje na změnu v charakteru modelovaného procesu.
- Nevýhodou bývá **požadavek na dostatečně dlouhé realizace** časové řady. Ztrácí se také možnost jednoduché interpretace výsledných modelů.

II. Box-Jenkinsonova metodologie

- V dalším předpokládejme, že náhodná posloupnost $\{Y_t, t \in \mathbb{Z}\}$ je **stacionární, centrovaná a druhého řádu**, tj. je stacionární ve střední hodnotě, která je rovna nule, je kovariančně stacionární, a má konečné druhé momenty.
- Základní modelová schémata:
 - **Autoregresní procesy** $AR(p)$
 - **Procesy klouzavých průměrů** $MA(q)$
 - Případně kombinace předchozích, $ARMA(p, q)$
- $ARMA$ proces řádu p, q je definován vztahem

$$Y_t - \varphi_1 Y_{t-1} - \dots - \varphi_p Y_{t-p} = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}, \quad (7)$$

kde $\varepsilon_t \sim WN(0, \sigma_\varepsilon^2)$

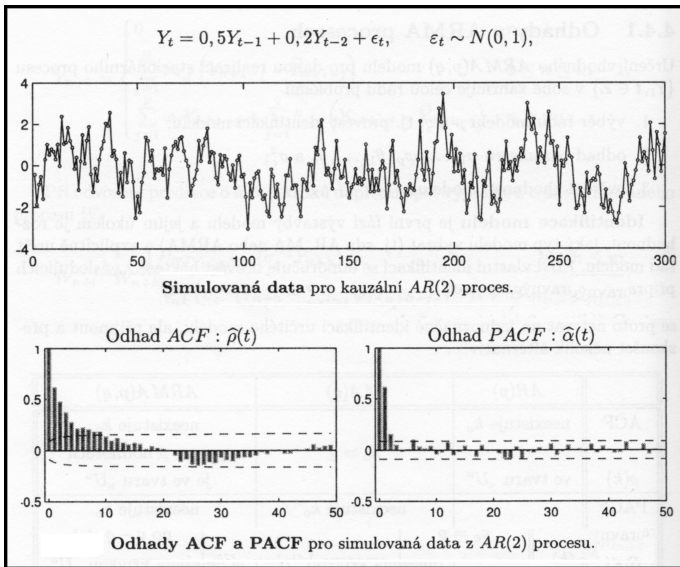
Odhady v $ARMA$ procesech

- Určení vhodného $ARMA(p, q)$ modelu pro danou realizaci stacionárního procesu v sobě zahrnuje
 - 1 výběr řádu modelu p a q , tj. provedení **identifikace modelu**
 - 2 odhad parametrů $\varphi_1, \dots, \varphi_p, \theta_1, \dots, \theta_q$ a σ_ε^2
 - 3 ověření vhodnosti modelu.
- Před provedením identifikace modelu se doporučuje vykreslit graf řady a pokud by byla střední hodnota nenulová, tak provést centrování řady.
- Představu o struktuře studovaného procesu získáme na základě zkoumání průběhu odhadnuté **autokorelační funkce** (ACF) a odhadnuté **parciální autokorelační funkce** (PACF).

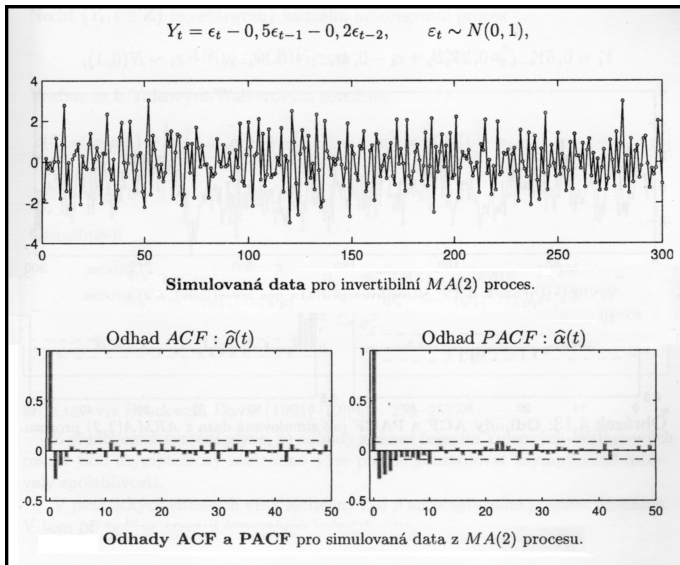
Autokorelační funkce

- Na základě teoretických výpočtů známe základní vlastnosti ACF a PACF v procesech AR , MA a $ARMA$
- AR proces
 - ACF funkce exponenciálně klesá k nule pro $t \rightarrow \infty$ a PACF pro $t > k_0$, kde k_0 je tzv. **identifikační faktor**, se výrazně neliší od nuly
- MA proces
 - Chování ACF a PACF je opačné oproti funkcím v AR procesu
- $ARMA$ proces
 - ACF i PACF exponenciálně klesají k nule pro $t \rightarrow \infty$, ovšem nelze určit identifikační bod, od kterého by se některá z korelačních funkcí výrazně lišila od nuly.

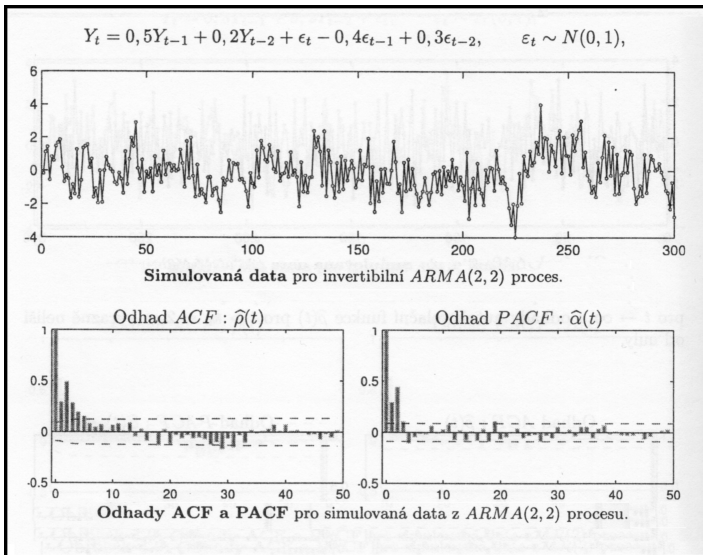
Příklad $AR(p)$ procesu



Příklad $MA(q)$ procesu



Příklad $ARMA(p, q)$ procesu



III. Spektrální analýza časových řad

- Klasická dekompozice a Box-Jenkinsonova metodologie jsou základní přístupy k analýze časových řad **v časové doméně**. **Ve spektrální doméně** patří mezi základní přístupy spektrální analýza, která je založena na Fourierově analýze.
- Spektrální analýza časových řad předpokládá, že lze časovou řadu vyjádřit pomocí funkcí $\sin(x)$ a $\cos(x)$ o rozličných amplitudách a frekvencích. Stejným faktorem zde není časová proměnná, ale faktor frekvenční.
- Vhodná při srovnávání chování několika řad, kdy můžeme porovnat řady v rámci jednotlivých frekvencí.

III. Spektrální analýza časových řad

- Předpokládejme opět, že náhodná posloupnost $\{Y_t, t \in \mathbb{Z}\}$ je **stacionární, centrovaná a druhého řádu**, tj. je stacionární ve střední hodnotě, která je rovna nule, je kovariančně stacionární, a má konečné druhé momenty.
- Důležitou vlastností stacionární náhodné posloupnosti je vlastnost, že její **autokovarianční funkci** lze vyjádřit jako nespočetný součet harmonických funkcí s různými amplitudami a frekvencemi.

III. Spektrální analýza časových řad

Spektrální hustota

- Podle Herglotzovy věty [1, str. 28] známe spektrální rozklad autokovarianční funkce stacionární posloupnosti

$$\gamma(t) = \int_{-\pi}^{\pi} e^{it\lambda} dF(\lambda), \quad (8)$$

kde funkce $F(\lambda)$ se nazývá **spektrální distribuční funkce** a je-li absolutně spojitá, pak existuje taková funkce $f(\lambda)$, že pro náhodné stacionární posloupnosti platí

$$F(\lambda) = \int_{-\pi}^{\lambda} f(x) dx \quad (9)$$

a funkce $f(\lambda)$ se pak nazývá **spektrální hustota**.

III. Spektrální analýza časových řad

Spektrální hustota

- Existuje-li spektrální hustota, pak můžeme psát

$$\gamma(t) = \int_{-\pi}^{\pi} e^{it\lambda} f(\lambda) d\lambda \quad (10)$$

- Pomocí Fourierovy transformace lze pak vyjádřit spektrální hustotu pomocí autokovarianční funkce

$$f(\lambda) = \frac{1}{2\pi} \sum_{t=-\infty}^{\infty} e^{-it\lambda} \gamma(t) \quad (11)$$

Spektrální hustota



Odhady spektrální hustoty

● PERIODOGRAM

- Periodogram je funkce definovaná pro n pozorování náhodné posloupnosti vztahem

$$I_n(\omega) = \frac{1}{2\pi n} \left| \sum_{t=1}^n Y_t e^{-it\omega} \right|^2 \quad \omega \in \langle -\pi, \pi \rangle \quad (12)$$

- $I_n(\omega)$ se dá považovat za **empirický odhad spektrální hustoty**, který je asymptoticky nestranným odhadem, ovšem není konzistentním – jeho rozptyl nekonverguje k nule, pokud vzrůstá délka posloupnosti pozorování.
- Díky svým vlastnostem je užitečným prostředkem pro vyhledávání významných periodických složek v časové řadě.

-  [1] FORBELSKÁ, Marie. *Stochastické modelování jednorozměrných časových řad*. Brno: Masarykova univerzita, 2009.
-  [2] KRIŠTOF, Aleš. *Nové metody a přístupy k analýze a prognóze ekonomických časových řad*. Praha, 2006. Disertační práce. Česká zemědělská univerzita v Praze.

Děkuji za pozornost.