

Statistické metody a zpracování dat

Analýza časových řad I.

Petr Dobrovolný

Základní pojmy

Časová řada je chronologicky uspořádaná posloupnost hodnot určitého statistického ukazatele.

$$y_t = f(t) \quad y_1, y_2, \dots, y_n \quad \begin{array}{l} y = \text{ukazatel} \\ t = \text{časová proměnná} \end{array}$$

y_t , kde $t=1, 2, \dots, n$ $n = \text{počet členů řady}$

Pomocí časových řad můžeme zkoumat **dynamiku** jevů v čase.

Mají základní význam pro **analýzu příčin**, které na tyto jevy působily a ovlivňovaly jejich chování v minulosti, tak pro **předvídaní** jejich budoucího vývoje.

Příklady časových řad a jejich použití

Vývoj cen akcií


Objem obchodování na burze

Vývoj počtu obyvatelstva určité lokality

Maximální denní srážkové úhrny na určité stanici

Průměrné měsíční teploty vzduchu na určité stanici

Průměrný roční odtok vody z povodí



Základní typy časových řad

Časové řady **deterministické** - neobsahují prvek náhody ($\sin(x)$) a **stochastické** (realizace náhodného procesu)

Časové řady **absolutních** veličin (přímo zjišťovaných)

- okamžikové (počet obyvatel – k datu sčítání)
- intervalové (denní úhrn srážek)

Časové řady **odvozené**

- průměrných veličin (řada klouzavých průměrů)
- poměrných – relativních veličin (řada hektarových výnosů)

Časové řady **ekvidistantní** a **neekvidistantní**

Problémy při sestavování časových řad

- Problém volby časových bodů pozorování
- Problémy s délkou časové řady
- Problémy s kalendářem
- Problémy s nesrovnatelností jednotlivých měření

Uvedené problémy mohou vést k narušení **homogenity** časové řady

Zásady pro sestavování časových řad

Metadata (data o datech) – historie měření vyšetřovaného prvku na meteorologické stanici, data výměny přístrojů, změny pozorovatelů, změny metodiky měření, ...


Homogenita časové řady – hodnoty jednotlivých členů pozorované řady odrážejí jen přirozenou proměnlivost studované veličiny a nejsou ovlivněny vnějšími vlivy.

- **absolutní** homogenita řady
- **relativní** homogenita řady – posuzování homogenity vůči řadě homogenní (vzorové)

Doplňování **chybějících** členů řady

Vylučování **odlehklých** hodnot.

Příklad nehomogenní řady



Maximální denní nárazy větru a počty dnů s nárazy větru na stanici Praha, Karlov v období 1921-1990

Okamžikové časové řady

Jsou spojité v čase, záleží u nich na rozhodném okamžiku šetření. Hodnota nezávisí na délce intervalu, za který je znak zjišťován. Okamžikové ukazatele za několik intervalů nesčítáme. Je však pro ně typické počítání průměrů v čase. Průměr okamžikové veličiny za určité období označujeme jako tzv. **chronologický průměr**. Nejprve spočteme průměr za časové okamžiky t_{i-1} a t_i , pro $i=2$ až n . Z těchto hodnot určíme průměr pro celou řadu:

$$\bar{y} = \frac{\frac{1}{2}y_1 + y_2 + \dots + y_{n-1} + \frac{1}{2}y_n}{n-1}$$


Uvedený vztah platí v případě, že délka všech intervalů je konstantní. Pokud ne, je nutné jednotlivé dílčí průměry vážit délkami intervalů a vypočítat vážený chronologický průměr.

Intervalové časové řady

Jednotlivé hodnoty se vztahují k **časovým úsekům** a přímo závisí na jejich délce. Za delší časové období lze intervalové ukazatele shrnovat a vytvářet **součtové (kumulativní) řady**. Součtová řada vznikne postupným sčítáním hodnot za sebou jdoucích časových intervalů. Podle průběhu součtové řady můžeme posoudit rovnoměrnost vývoje hodnot znaku. Hodnotu intervalového ukazatele zjištěnou za časový interval (t_{i-1}, t_i) označme q_i a přiřazujeme ji ke středu časového intervalu. Časovou řadu hodnot q_i označujeme intervalovou **řadou běžných hodnot**.

Požadavkem sestavování intervalových časových řad je **konstantnost** délky časového intervalu. V řadě případů tento požadavek není splněn (např. počet dnů v měsíci). Dalším typem součtových časových řad jsou **řady klouzavých úhrnů**. Jsou vhodné ke srovnání úrovně řady ve sledovaném období s úrovní řady období předešlého.


Z - diagram



Řady běžných hodnot, řady kumulovaných hodnot a řady klouzavých úhrnů lze znázornit v tzv. Z-diagramu

Odvozené časové řady

Jedná se o řady sestavné z průměrů či z relativních (poměrných) hodnot. V podstatě se jedná o řady okamžikové. Průměr okamžikového ukazatele je též okamžikovou veličinou. Nejedná se u nich o závislost na délce intervalu, ale na hodnotách znaku v daném intervalu (např. průměrné počty zaměstnanců místo okamžikových údajů či tzv. klouzavé průměry na místo ročních hodnot – viz. obr.)



Odvozené ukazatele časové řady

Při práci s časovými řadami je typické, že často pracujeme ne přímo s původní časovou řadou, ale s nějakou její **transformací**.

Absolutní přírůstek (první diference) $\Delta y_t = y_t - y_{t-1}$

Jsou-li členy v řadě absolutních přírůstků prakticky konstantní, potom řada má lineární trend.

Relativní přírůstek $\delta_t = \frac{\Delta y_t}{y_{t-1}} = \frac{y_t - y_{t-1}}{y_{t-1}} = \frac{y_t}{y_{t-1}} - 1$

Informuje nás o rychlosti (tempu) růstu

Odvozené ukazatele časové řady

Koeficient růstu (**řetězový index**): vyjadřuje, o kolik procent vzrostla hodnota časové řady v okamžiku t_i ve srovnání s hodnotou řady v čase t_{i-1} .

$$k_i = \delta_i + 1 = \frac{y_i}{y_{i-1}} \cdot 100(\%)$$

Průměrný koeficient růstu: pro celou řadu se vypočte jako geometrický průměr jednotlivých hodnot koeficientů růstu.

$$\bar{k} = \sqrt[n]{k_1 \cdot k_2 \cdot \dots \cdot k_{n-1}} = \sqrt[n]{\frac{y_2}{y_1} \cdot \frac{y_3}{y_2} \cdot \dots \cdot \frac{y_n}{y_{n-1}}} = \sqrt[n]{\frac{y_n}{y_1}}$$

Uvedený výpočet je vhodný pouze v případě stálého a přibližně stejného růstu hodnot řady.

Odvozené ukazatele časové řady

Pro účely srovnání různých časových řad se jejich hodnoty převádějí na tzv. **bazické indexy** (indexy se stálým základem):

$$k'_i = \frac{y_i}{y_z} \cdot 100(\%)$$

Hodnota y_z je obvykle prvním nebo posledním členem časové řady (základ).

Transformace časové řady


Jedná se o úpravu původní časové řady, tak aby

1. splňovala podmínky pro následnou analýzu (např. linearizace, stacionarita atd.)
2. zvýrazňovala dále analyzovanou složku

Běžné druhy transformací:

- přidání konstanty $y = y + C$
- linearizace řady $y = \ln(y)$
- odečtení průměru $y = y - \bar{y}$
- standardizace $y = \left(\frac{y - \bar{y}}{s_d} \right)$
- odečtení hodnot trendové funkce (viz. stacionarita)

Stacionární řada



Stacionarita je jednou z nutných podmínek řady metod analýzy časové řady

Časovou řadu považujeme za stacionární, pokud splňuje následující podmínky:


- má konstantní průměr
- má konstantní variabilitu
- korelace dvou časově posunutých pozorování (autokorelace) závisí na délce posunu

Stacionaritu lze docílit transformací na řadu diferencí či odečtením trendu

Základy analýzy časových řad

Hlavní cíle analýzy časových řad

1. odhalení zákonitosti a příčin dosavadního **vývoje**
2. **prognóza** chování časových řad




Každá řada může obsahovat čtyři základní složky:

- **trend (T_j)**
- **periodická (sezónní) složka (S_j)**
- **cyklická složka (C_j)**
- **náhodná složka (ε_j)**

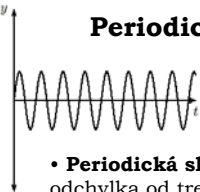
První tři složky tvoří systematickou část řady.

Trendová složka časové řady



- **Trend** je obecná tendence vývoje zkoumaného jevu za dlouhé období.
- Je výsledkem dlouhodobých a stálých procesů (v měřítku posuzované délky časové řady).
- Trend může být lineární či nelineární.
- Trend může být rostoucí, klesající nebo může existovat řada bez trendu.
- Časové řady bez trendu se označují jako stacionární.

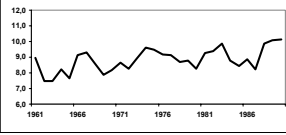
Periodická složka časové řady



$$f(t_i) = f(t_i + T)$$

- **Periodická složka** je pravidelně se opakující odchylka od trendové složky s pevnou délkou **periody T**.
- Perioda této složky je menší než celková velikost sledovaného období.
- Typickým případem jsou **sezónní kolísání** a nebo řady denních, měsíčních, čtvrtletních ukazatelů.
- Příčiny sezónnosti jsou různé, většinou však dobře definovatelné.
- Sezónnost je typická pro časové řady ekonomických ukazatelů.

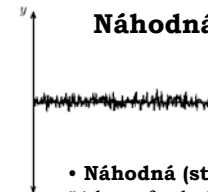
Cyklická složka



$$f(t_i) \approx f(t_i + \bar{T})$$

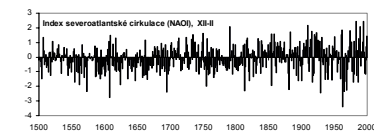
- **Cyklická složka** udává kolísání okolo trendu v důsledku dlouhodobého cyklického vývoje.
- Cyklická složka může vykazovat změny v délce a amplitudě cyklu.
- Délka cyklu je tedy většinou neznámá. (př. demografický trend, kolísání teploty vzduchu).
- Délka cyklu je tedy delší než 1 rok. V některých případech se označuje jako „střednědobý trend“.
- Bývá typickou součástí časových řad meteorologických prvků (př. problém globálního oteplování) či hydrologických jevů.

Náhodná složka časové řady



- **Náhodná (stochastická) složka** se nedá popsat žádnou funkcí času.
- "Zbývá" po vyloučení trendu, sezónní a cyklické složky.
- Jejím zdrojem jsou v **jednotlivostech** nepostizitelné jevy.
- Lze ji však popsat pravděpodobnostně.

Grafické metody analýzy časových řad



- První analýza spočívá v grafickém znázornění průběhu řady.
- Graf slouží k prvotnímu posouzení tendence změn či k hledání opakujících se jevů („patterns“).
- I tyto jednoduché metody umožňují velmi krátkodobou předpověď.
- Graf však velmi dobře může znázorňovat nehomogenity, porovnávat dvě či více řad mezi sebou, ...
- Slouží k výběru vhodné metody analýzy.

Modely analýzy časových řad

Časová řada – hodnota ukazatele je funkcí času a náhodné složky:

$$y_t = f(t, \varepsilon_t)$$

K analýze a popisu časových řad se používá několika základních modelů:

- Klasický (formální) model**
- Box-Jenkinsova metodologie**
- Lineární dynamické a regresní modely**
- Spektrální analýza**

Klasický (formální) model

Klasický model je pouze popisem jednotlivých složek časové řady jako forem pohybu, ne poznáním příčin.

Jedná se o **dekompozici** na jednotlivé složky a jejich formální popis modelem:


- **Aditivním**
- **Multiplikativním**

Základem je popis systematické složky (trendu, cyklických a periodických kolísání).

Vychází se z předpokladu, že jednotlivá pozorování jsou vzájemně nekorelovaná (viz. také problém stacionarity časových řad).

Aditivní model


$$y_t = Y_t + \varepsilon_t = T_t + S_t + C_t + \varepsilon_t$$



Model časové řady s aditivní sezónní složkou

Multiplikativní model

$$y_t = T_t \cdot S_t \cdot C_t \cdot \varepsilon_t$$



Model časové řady s multiplikativní sezónní složkou

Box-Jenkinsova metodologie

- Považuje za základní prvek konstrukce modelu časové řady **náhodnou složku**, která může být tvořena korelovanými náhodnými veličinami. Těžištěm analýzy je korelační analýza více či méně závislých pozorování uspořádaných do časové řady.
- Celkový model časové řady sestává ze dvou složek: modelu **autoregresního** (AR) a modelu **klouzavých průměrů** (MA)
- Tyto metody jsou mnohem flexibilnější než dekompoziční metody, mnohem rychleji se adaptují na změny charakteru časové řady. Základní modely se konstruují přímo z dat.

Lineární dynamické a regresní modely

- Jedná se o **kauzální modely** – hledají příčinné vazby.
- Vysvětlovaná proměnná je vysvětlována pomocí jedné nebo více vysvětlujících proměnných.
- Většinou se předpokládají lineární nebo linearizované závislosti mezi proměnnými.
- Modely se konstruují na základě teoretických předpokladů.
- Lineární dynamické modely se používají např. v humánní geografii či v ekonometrii, v hydrologii – např. model odtoku.

Spektrální analýza

- Je založena na předpokladu, že časová řada je součtem funkcí sin a cos o rozličných amplitudách a frekvencích.
- Tato koncepce především umožňuje nalézt významná cyklická kolísání.
- Pracuje s pojmy **spektrum a frekvence**.
- Analýza vyšetřuje spektrum řady (tj. zjišťuje intenzitu zastoupení jednotlivých frekvencí a jejich parametrů v časové řadě).
- Předmětem analýzy není časová proměnlivost ale změny ve frekvencích.

Modely jednorozměrné a vícerozměrné

- Modely A, B a D lze označit jako jednorozměrné.
- Modely C, založené na předpokladu, že vývoj analyzovaného ukazatele není ovlivňován pouze časovým faktorem, ale řadou jiných ukazatelů (příčinných, faktorových) se označují jako vícerozměrné:

$$y_t = f(t, x_1, x_2, \dots, x_p, \varepsilon_t)$$

Navíc vlivy faktorů x_i na hodnotu y se nemusí projevit jen v čase t , ale mohou být rozloženy do několika časových období

$$y_t = f(t, x_{1,t}, x_{1,t-1}, \dots, x_{1,t-z}, \dots, x_{p,t}, x_{p,t-1}, \dots, x_{p,t-z}, \varepsilon_t)$$

kde z_i je maximální časové zpoždění i -tého ukazatele x .

Předpovědi v časových řadách

Bodová předpověď – představuje v jistém smyslu nejlepší odhad budoucí hodnoty zpracovávané časové řady. Je zatížena chybou, proto se často doplňuje tzv. **předpovědním intervalem** (analogie intervalů spolehlivosti). Vymezuje interval hodnot, do něhož budoucí hodnota řady náleží s jistou pravděpodobností.

Kvantitativní předpovědi – objektivní, na základě statistické analýzy. Jsou extrapolací – prodloužením minulých a současných hodnot za předpokladu, že i v budoucnu bude platit námi použitý model.

Předpovědi v časových řadách

Horizont předpovědi – časová vzdálenost předpovídané hodnoty od okamžiku konstrukce (počátku) předpovědi.

Chyba předpovědi – rozdíl mezi skutečnou y_t a předpovězenou hodnotou \hat{y}_t řady v čase t :

$$e_t = y_t - \hat{y}_t$$

Metody předpovědi se konstruují nejprve pro známý úsek časové řady aby bylo možné výše uvedené porovnáni.

Hlavním zdrojem chyby předpovědi je náhodná složka. Je-li její podíl v časové řadě značný, předpověď často nemá smysl konstruovat.

Velké chyby v předpovědi však mohou indikovat také nevhodně použitý model časové řady a předpovědní techniky.

Míry pro hodnocení kvality předpovědi

Součet čtvercových chyb (SSE – Sum of Squared Errors)

$$\sum_{t=1}^n (y_t - \hat{y}_t)^2 = \sum_{t=1}^n e_t^2$$

Střední čtvercová chyba (MSE – Mean Squared Error)

$$\sum_{t=1}^n \frac{(y_t - \hat{y}_t)^2}{n} = \sum_{t=1}^n \frac{e_t^2}{n}$$

Střední absolutní chyba (MAE – Mean Absolute Error)

$$\sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{n} = \sum_{t=1}^n \frac{|e_t|}{n}$$

Analýza trendu

A. Klasický přístup založený na matematicko-statistickém modelování. Modelované parametry jsou **KONSTANTNÍ** v čase. Neadaptivní metody – např. regresní modely. Umožňují snadnou předpověď (spolehlivou?).

B. Adaptivní přístup – parametry se v čase **VYVÍJEJÍ**. Například charakter lineárního trendu se mění (mění se směrnice trendu). Za jednoduchou adaptivní metodu lze považovat i metodu klouzavých průměrů.

Adaptivní metody představují především modely exponenciálního vyrovnávání. Používají metody „zapomínání“ starých hodnot řady. Poskytují kvalitní krátkodobé předpovědi, ale většinou vylučují možnost kvalitních dlouhodobých předpovědí.

Analýza trendu – základní metody vyrovnávání:

- analytické (popis časové řady funkcí)
- mechanické (klouzavé průměry)
- exponenciální vyrovnávání

Přístupy založené na subjektivním (**grafickém**) hodnocení trendu v časové řadě. Často poskytují dostatečně přesný způsob očištění časové řady, používají se např. také při rozhodování o volbě objektivních metod (např. vhodné křivky).


Analýtické vyrovnávání trendu matematickou křivkou

$$y_t = Tr_t + E_t$$

- Patří mezi neadaptivní metody. Vychází z předpokladu, že se trend po celou sledovanou dobu nemění a že je možné ho popsat některým typem matematické křivky.
- Identifikace trendu se redukuje na výběr správného typu matematické křivky a odhad jejich parametrů.
- Na problém analýzy trendu lze pohlížet jako na speciální případ **regresní závislosti**, kdy nezávisle proměnnou je čas.
- Časovou řadu vyrovnáváme křivkou, která nejlépe vystihuje její vývojový trend. Výpočet parametrů křivky se děje **metodou nejmenších čtverců**.

Lineární trend

$$y_t = b_0 + b_1 t$$



Parametr b_1 představuje přírůstek hodnoty y připadající na jednotkovou změnu časové proměnné. Řada se vyznačuje konstantními absolutními přírůstky (první diference).

Lineární trend

Hodnoty parametrů b_0 a b_1 získáme metodou nejmenších čtverců obdobně jako v případě jednoduché lineární regrese, tedy:

$$b_1 = \frac{\sum_{t=1}^n t y_t - \bar{t} \sum_{t=1}^n y_t}{\sum_{t=1}^n t^2 - n \bar{t}^2} \quad b_0 = \bar{y} - b_1 \bar{t}$$

Předpověď budoucí hodnoty (**bodová předpověď**) má tvar:

$$\hat{y}_T = b_0 + b_1 T$$

Lineární trend

Intervalová předpověď – konstrukce (1-p) 100 procentního intervalu spolehlivosti

$$(\hat{y}_T - t_{n-2}(p) s f_T; \hat{y}_T + t_{n-2}(p) s f_T)$$


kde

$$s = \sqrt{\frac{\sum_{t=1}^n y_t^2 - \frac{(\sum_{t=1}^n y_t)^2}{n}}{n-2}} \quad f_T = \sqrt{1 + \frac{1}{n} + \frac{(T-\bar{t})^2}{\sum_{t=1}^n t^2 - n \bar{t}^2}}$$

Symbol $t_k(p)$ označuje kritickou hodnotu t-rozdělení s k stupni volnosti na hladině významnosti p .

Exponenciální trend

$$y_t = b_0 \cdot b_1^t$$



Parametr b_1 představuje průměrný přírůstek hodnot y_t . Ty se chovají jako členy geometrické posloupnosti.


Protože se již nejedná o funkci lineární v parametrech, lze k odhadu exponenciálního trendu využít metody nejmenších čtverců pouze po její **logaritmické transformaci**:

$$\log y_t = \log b_0 + t \cdot \log b_1$$

Modifikovaný exponenciální trend


$$y_t = \xi + b_0 \cdot b_1^t$$

kde $b_1 > 0$



Patří do kategorie funkcí, které mají ve svém vývoji asymptotu (viz. obr). Používají se, jestliže podíly sousedních hodnot prvních diferencí analyzované řady jsou přibližně konstantní. Absolutní člen se nazývá parametr posunutí a k odhadu parametrů nelze použít MNC.

Polynomický trend



$$y_t = b_0 + b_1 t + b_2 t^2 + \dots + b_k t^k$$


Při volbě stupně polynomu je třeba postupovat opatrně. Vyšší stupeň zajišťuje těsnější proložení empirických hodnot křivkou, vede ale k nestabilitě trendu.

Vyšší polynomy se většinou vůbec nehodí k extrapolacím.

K odhadu parametrů lze využít MNC.

Logistická křivka


$$y_t = \frac{1}{k + b_0 \cdot b_1^t}$$



Křivka má tři úseky, první je charakterizován pozvolným vzestupem, druhá v okolí inflexního bodu prudkým růstem a třetí určitou vrcholovou stagnací. Uvedený tvar je jeden z mnoha různých funkčních předpisů popisujících křivku s charakteristickým průběhem ve tvaru písmena S.

Gompertzova křivka

$$y_t = k \cdot b_0^{b_1^t}$$



Křivka s podobným esovitým průběhem jako logistika, ale na rozdíl od ní je asymetrická. Těžiště hodnot je až za inflexním bodem.

Verifikace modelu

Je zapotřebí zhodnotit statistickou **významnost** odhadnutých **parametrů** modelu i **modelu** jako celku.

MNČ – podstatou je, že model vždy vysvětlí pouze **část** variability (proměnlivosti) pozorovaných dat.


Je nutné zjistit (testovat), zda model jako celek dává lepší vysvětlení, než je možné očekávat jako důsledek náhody a to na jisté hladině významnosti.

Koeficient determinance R² – základní ukazatel vhodnosti použitého modelu (vzorec a interpretace viz. korelační počet)

Analýza rozptylu

Analýza rozptylu

$$s_y^2 = s_{\hat{y}}^2 + s_{y-\hat{y}}^2$$



Rozptyl empirických hodnot

$$s_y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$$

Rozptyl vyrovnaných hodnot

$$s_{\hat{y}}^2 = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

Rozptyl reziduální

$$s_{y-\hat{y}}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Interpretace výsledků analýzy rozptylu

VÝSLEDEK									
Regressní statistika									
Násobná R	0,707111								
Hodnota spolehlivosti R	0,636343								
Nastavení hodnota spolehlivosti R	0,575733								
Chyba stří. hodnoty	1,192911								
Pozorování	8								
ANOVA									
	Regression	Residual	Total	F	Significance F				
	1	14,54264	14,54264	10,49006895	0,017681891				
	6	0,538214	1,423036						
	7	20,47975							
ANOVA		Koeficienty stří. hod.	t stat.	Abstrakce P	Grady 95%	Možná 95%	Grady 95%	Možná 95%	
	France	0,396245	0,325908	27,32176	1,39438E-05	23,97944851	28,228	23,87914	28,228
	1	0,15407	0,15407	3,240325	0,017681891	0,146024926	1,046932	0,146025	1,046932

Kritéria pro volbu vhodného modelu trendové funkce I.

A. Volba vhodné trendové funkce by v první řadě měla vycházet z **věcné analýzy zkoumaného jevu**.

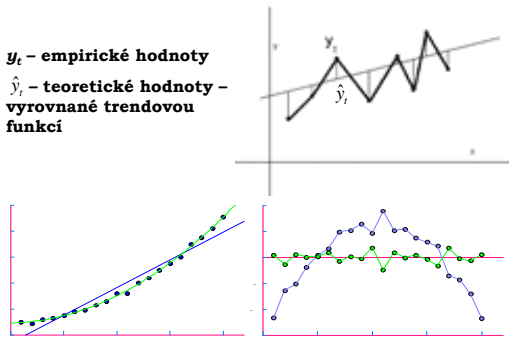
Ta nám umožní zaměřit se na určité typy (skupiny) funkcí či některé jiné předem vyloučit – jde o funkci rostoucí či klesající, má inflexní bod či je nekonečně rostoucí.

Pro použitou trendovou funkci je důležité, zda má (logistický trend) či nemá (lineární trend – růst řady není ničím omezen) asymptotu. Je to důležité pro předpovídání chování časové řady.

Kritéria pro volbu vhodného modelu trendové funkce II.

B. Analýza grafu časové řady a analýza reziduí.

y_t - empirické hodnoty
 \hat{y}_t - teoretické hodnoty -
 vyrovnané trendovou
 funkcí



Objektivní kritéria pro volbu vhodného modelu trendové funkce I

Spočívají v minimalizaci předem zvoleného kritéria (jako v případě regresní analýzy). Za toto kritérium se nejčastěji bere součet čtverců odchylek empirických hodnot y_t od hodnot vyrovnaných \hat{y}_t (**součet čtvercových chyb**):

$$SSE = \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

Z uvažovaných funkcí se vybírá ta s nejmenší hodnotou reziduálního součtu čtverců.

POZOR - jde o formální kritérium. Např. použijeme-li polynom vysokého stupně, může být reziduální součet čtverců i nulový, avšak zcela nepoužitelný.

Objektivní kritéria pro volbu vhodného modelu trendové funkce II

Druhým kritériem je tzv. **index korelace**, jehož vzorec lze zapsat následujícím způsobem:

$$I = \sqrt{1 - \frac{\sum (y_t - \hat{y}_t)^2}{\sum (y_t - \bar{y})^2}}$$

Čitatel zlomku - suma odchylek vyrovnaných hodnot od hodnot empirických

Jmenovatel zlomku - suma odchylek vyrovnaných hodnot od průměru empirických hodnot

Za nejhodnější se považuje funkce s největší hodnotou indexu korelace. K jeho používání však platí stejné výhrady jako k výše uvedenému kritériu

Objektivní kritéria pro volbu vhodného modelu trendové funkce III

Počítačové programy obvykle nabízejí následující míry úspěšnosti zvolené trendové funkce:

Střední chyba odhadu (M.E. - Mean Error)

$$M.E. = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)}{n}$$

Střední čtvercová chyba odhadu (M.S.E. - Mean Square Error)

$$M.S.E. = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}$$

Je to nejpoužívanější kritérium.

Střední absolutní chyba odhadu (M.A.E. - Mean Absolute Error)

$$M.A.E. = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n}$$

Střední absolutní procentní chyba odhadu (M.A.P.E. - Mean Absolute Percentage Error)

$$M.A.P.E. = \sum \left(\frac{|y_t - \hat{y}_t|}{y_t} \right) \cdot \frac{100}{n}$$

Střední procentní chyba odhadu (M.P.E. - Mean Percentage Error)

$$M.P.E. = \sum \left(\frac{y_t - \hat{y}_t}{y_t} \right) \cdot \frac{100}{n}$$

Informativní testy pro volbu vhodné trendové křivky:

Trend	Informativní test
lineární	První diference $(y_{t+1} - y_t)$ jsou přibližně konstantní
kvadratický	Druhé diference $(y_{t+2} - 2y_{t+1} + y_t)$ jsou přibližně konstantní
exponenciální	Podíly sousedních hodnot (y_{t+1}/y_t) resp. První diference logaritmu tvaru $(\log y_{t+1} - \log y_t)$ jsou přibližně konstantní
logistický	Křivka prvních diferencí $(y_{t+1} - y_t)$ se podobá křivce normální hustoty, podíly $(1/y_{t+2} - 1/y_{t+1}) / (1/y_{t+1} - 1/y_t)$ jsou přibližně konstantní
Gompertzova křivka	Podíly $(\log y_{t+2} - \log y_{t+1}) / (\log y_{t+1} - \log y_t)$ jsou přibližně konstantní