


Statistické metody a zpracování dat

VIII Analýza časových řad

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 pojmy

Casová řada je chronologicky uspořádaná posloupnost hodnot určitého statistického ukazatele.

$$y_t = f(t) \quad y_1, y_2, \dots, y_n \quad y = \text{ukazatel} \\ t = \text{casová proměnná} \\ y_t, \text{kde } t=1, 2, \dots, n \quad n = \text{počet členů řady}$$

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.

Základní typy časových řad

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

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

- 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 **homogeneity** časové řady

Maximální denní nárazy větru a počty dnů s nárazy větru na stanici Praha, Karlův 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 zjištován.

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 scítáním 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-j}, t_j) označme q_i a přiřazujeme ji ke středu časového intervalu.


Casovou řadu hodnot q_i označujeme intervalovou **řadou běžných hodnot**.

Požadavkem sestavování intervalových časových řad je **konstantnost** délky časového intervalu. V řadě případu 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 predešlého.

Z - diagram


Rady 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.

Nejdříve 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) $\Delta y_i = y_i - y_{i-1}$

Jsou-li členy v řadě absolutních přírůstků prakticky konstantní, potom hodnoty řady lineárně rostou (klesají).

$$\text{Relativní přírůstek} \quad \delta_i = \frac{\Delta y_i}{y_{i-1}} = \frac{y_i - y_{i-1}}{y_{i-1}} = \frac{y_i}{y_{i-1}} - 1$$

Informuje nás o rychlosti (tempu) růstu

Odvozené ukazatele časové řady

Koefficient růstu (**retězový 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 koefficient růstu: pro celou řadu se vypočte jako geometrický průměr jednotlivých hodnot koefficientů růstu.

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

Uvedený výpočet je vhodný pouze v případě stálého a přibližně stejněho 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).

Odvozené ukazatele časové řady

	B	C	D	E	F	G	H
6	měsíc	t	tržba	absolutní přírůstek	relativní přírůstek	řetězový index koeficient růstu (z=1)	bazický index
7	leden	1	328541	-	-1.0309	99.0	100.0
8	únor	2	325154	-3387	-1.0309	99.0	99.0
9	březen	3	330244	5090	1.5654	101.6	100.5
10	duben	4	329570	-674	-0.2041	99.8	100.3
11	květen	5	332489	2919	0.8857	100.9	101.2
12	červen	6	340025	7536	2.2665	102.3	103.5
13	červenec	7	338962	-1063	-0.3126	99.7	103.2
14	srpen	8	342110	3148	0.9287	100.9	104.1

- Absolutní přírůstek =D8-D7
- Relativní přírůstek =E8/D7*100
- Řetězový index =D8/D7*100
- Bazický index =D8/\$D\$7*100

Odvozené ukazatele časové řady



Transformace časové řady

Jedná se o úpravu původní časové řady, tak aby

1. splňovala podmínky pro následnou analýzu (např. 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 | $y = \frac{y - \bar{y}}{s_d}$ |
| • 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


Stacionarity lze docílit transformací na řadu diferenci 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_t)**
- periodická (sezónní) složka (S_t)**
- cyklická složka (C_t)**
- náhodná složka (ϵ_t)**

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 (s nulovým trendem).
- Časové řady bez trendu se označují jako stacionární.

y

Periodická složka časové řady




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

- **Periodická složka** je pravidelně se opakující odchylka od trendové složky s pevnou délkom **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 důsledkem 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.


y

Náhodná složka časové řady




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

Grafické metody analýzy časových řad



- Prvotní analýza spočívá v grafickém znázornění průběhu řady.
- Graf slouží k prvotnímu posouzení tendencie 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.

Grafické metody analýzy časových řad



Vývoj kurzu akcií – příklad výskytu jednoduchých obrazců (patterns) v časové řadě

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:

A. 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 např. tzv. **aditivním modelem**:
- Základem je popis systematické složky (trendu, cyklických a periodických kolísání).




Analýza trendu

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

Analýza trendu – základní metody vyrovnávání:

- analytické (popis časové řady funkcí)
- mechanické (klouzavé průměry)
- ...




Analytické 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 jejích 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 dělá **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. Rada 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:

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


Exponenciální trend



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 nejménších čtverců pouze po její **logaritmické transformaci**:

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

Polynomický trend




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 MNČ.

Logistická křivka



Křivka má tři úseky, první je charakterizován pozvolným vzestupem, druhá v okolí inflexního bodu prudkým růstem a třetí určitou vrcholovou stagnací. (patří mezi tzv. S-křivky).

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.

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

Analýza rozptylu



$$S_y^2 = S_{\hat{y}}^2 + S_{y-\hat{y}}^2$$

A. Rozptyl empirických hodnot (celkový)

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

B. Rozptyl vyrovnaných hodnot (modelový)

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

C. Rozptyl reziduální

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

Interpretace výsledků analýzy rozptylu

Model vysvětuje více než 63 % proměnlivosti studované charakteristiky v čase

VÝSLEDEK						
Regresní statistika						
Násobné R	0,797711					
Hodnota spolehlivosti R	0,636343					
Nastavená hodnota spolehlivosti R	0,597533					
Chyba stř. hodnoty	1,192911					
Pozorování	8					
ANOVA						
	Rozdíl	SS	MS	F	Významost F	p-hodnota
Regrese	1	14,94054	14,94054	10,4990538	0,017681891	
Residua	6	8,538214	1,423036			
Celkem	7	23,47875				
	Koefficienty sif. hod.	t stat.	Hodnota P	Doh. 99%	Horní 95% Doh. 95%	Dolní 95% Doh. 95%
Hranice	25,85352	0,929506	27,92182	1,35625E-07	23,67914451	28,228
t	0,598429	0,16407	3,240225	0,017681891	0,146024926	1,046032

Interpretace: p < 0,05 - existuje statisticky významný rozdíl mezi rozptylem vysvětleným regresní přímkou (tedy modelem trendu) a zbytkovým (reziduálním) rozptylem – zvolený model trendu je vhodný

Kritéria pro volbu vhodného modelu trendové funkce I.


A. Volba vhodné trendové funkce by v prvé 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 nicméně 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**.



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 III

Počítacové 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 logaritmů tvaru $(\log y_{t+1} - \log y_t)$ jsou přibližně konstantní
logistiky	Křivka prvních differenc $(y_{t+1} - y_t)$ 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

Mechanické vyrovnávání trendu metodami klouzavých průměrů

Používá se v případě, že se trend mění a nelze ho vyrovnat „globálně“ jednou matematickou křivkou. Metoda je vhodná pro neperiodické řady, neumožňuje extrapolaci hodnot.



Vlastní průměry se používají jako **prosté** či **vážené**. V některých případech lze použít klouzavých mediánů. Klouzavé průměry mohou být **necentrované** a **centrované**.

Metody klouzavých průměrů


Jako klouzavé průměry obecně označujeme lineární kombinace členů původní řady.

$$\text{prosté} \quad \frac{1}{5}(y_{t-2} + y_{t-1} + y_t + y_{t+1} + y_{t+2})$$

$$\text{vážené} \quad \frac{1}{8}(y_{t-2} + 2y_{t-1} + 2y_t + 2y_{t+1} + y_{t+2})$$


Patří mezi tzv. **adaptivní** přístupy k trendové složce časové řady.

Tzv. **polynomické** klouzavé průměry umožňují vyrovnání hodnot na počátku a konci časové řady



Volba řádu klouzavých průměrů

- Subjektivní posouzení charakteru dat
- Délka klouzavých průměrů by měla odpovídat periodě sezónních či cyklických fluktuací
- Vzorce pro výpočet optimální délky



Obsahuje-li řada sezónní složku, je vhodné volit řád klouzavých průměrů tak, aby zahrnoval celou délku periody sezónní složky.

Centrované klouzavé průměry

Ve většině případů se používají klouzavé průměry liché délky, u **sudé délky** je problém s přiřazením hodnot časovému okamžiku.

V ekonomických časových řadách, které často obsahují sezónní složku délky 4 (řady čtvrtletních hodnot) či 12 (řady měsíčních hodnot), se tento problém řeší tzv. **centrováním**.

Výsledné klouzavé průměry pro sudou délku klouzavé části vypočteme jako **průměry dvou sousedních klouzavých průměrů** liché délky.

Centrované klouzavé průměry


Příklad: Abychom vystihli roční chod určitého ukazatele, chceme pro řadu měsíčních hodnot použít klouzavých průměrů délky 12.

Shlazená hodnota však spadá doprostřed mezi „červen“ a „červenec“. Další shlazená hodnota pak mezi „červenec“ a „srpen“.

Tyto dva jednoduché klouzavé průměry vezmeme a zprůměrníme. Výsledek pak už můžeme přiřadit k „červencové“ hodnotě. Tedy vytváříme klouzavé průměry o délce 13:

$$\hat{y}_t = \frac{1}{2} \frac{1}{12} (y_{t-6} + y_{t-5} + \dots + y_{t+5}) + \frac{1}{12} (y_{t-5} + y_{t-4} + \dots + y_{t+6}) = \\ \frac{1}{24} (y_{t-6} + 2y_{t-5} + 2y_{t-4} + \dots + 2y_{t+5} + y_{t+6})$$

Centrované klouzavé průměry




Obecně místo jednoduchých klouzavých průměrů délky 2m vytváříme centrované klouzavé průměry délky 2m+1 podle tohoto obecného vzorce:

$$\hat{y}_t = \frac{1}{4m} (y_{t-m} + 2y_{t-m+1} + \dots + 2y_{t+m-1} + y_{t+m})$$

m - polovina řádu klouzavých průměrů (shlazovacího okna)


Vážené klouzavé průměry

- Jednotlivé členy úseku řady přiřazeny váhy.
- Tyto váhy většinou lineárně klesají směrem od středního (vyrovnaného) člena.
- Váhy mohou mít také např. podobu tzv. gaussova filtru.



Analýza časových řad v programu Statistica

Statistiky-Pokročilé lineární/nelineární modely-Časové řady/Predikce



Výpočet klouzavých průměrů

... a EXCEL



Pozor na vykreslování klouzavých průměrů v programu EXCEL !!!

Analýza sezónní složky časových řad (sezónní očištování)

- klasický přístup k sezónní dekompozici
- úvod do autokorelační analýzy

Sezónní složka S_t je typická pro časové řady, jejichž interval pozorování je kratší než jeden rok (sezóna může mít délku týden, měsíc, roční období).

Objevuje se v řadách ekonomických (tržby, produkce, ...), ale i v řadách meteorologických prvků (roční chod teploty vzduchu).

Řada obsahující sezónní složku se vyznačuje pravidelným opakováním hodnot kolem trendu a toto opakování může mít délku např. 7 dnů (do týdne), 12 měsíců či 4 roční období (do roku).

Sezónní složka může mít aditivní resp. multiplikativní charakter


Obecný model řady při sezónním očištování

Trendovou a cyklickou složku považujeme za jeden celek:


aditivní model: $Y_t = TC_t + S_t + \varepsilon_t$

Y_t je pozorovaná hodnota časové řady v čase t .


Statistiky-Pokročilé lineární/nelineární modely-Časové řady/Predikce



Jednotlivé kroky analýzy sezónní složky




1. Z originální řady obsahující sezónní složku je vypočtena řada **klouzavých průměrů** s délkou klouzavých průměrů rovnou délce sezónní složky.




2. Vytvoříme novou řadu jako rozdíl řady **původní** a řady **shlazené**.

Jednotlivé kroky analýzy sezónní složky

Graf promítnutí: SALES
U.S. total retail sales; Sezónní řádky (sezóna=12);



3. Tzv. **sezónní komponenty** jsou vypočteny jako průměr pro každý člen v rámci sezóny. Výsledné hodnoty představují průměrnou sezónní složku v časové řadě.



4. **Sezónně očištěná řada** (tedy řada obsahující vedle náhodné složky ještě složku TC) se potom vyjádří jako rozdíl řady originální a sezónní komponenty.



Autokorelace časových řad

Autokorelační analýza - metoda, kterou lze zkoumat vzájemné vztahy mezi hodnotami jedné časové řady. Může sloužit jako metoda k definování sezónní a cyklické složky časových řad.

Jejím základem je výpočet **autokorelačního koeficientu**, resp. **autokorelační funkce**.

Autokorelační koeficient

Autokorelační koeficient r_k je relativní míra proměnlivosti členů časové řady posunutých o určitou hodnotu k . Definuje vztah mezi členy časové řady y_t a y_{t+k} .

Posun k se z angličtiny označuje jako **lag**. Je to tedy korelační koeficient vypočtený mezi jednotlivými členy časové řady, mezi kterými je $k-1$ jiných pozorování tedy $lag = k$ a označujeme ho jako autokorelační koeficient k -tého řádu.

Pro $k = 0$ je hodnota $r_0 = 1$ - je to vlastně hodnota korelačního koeficientu.

Základní pojmy

Rozptyl (variance) – míra variabilita (proměnlivosti) statistického znaku x

$$s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

Kovariance – absolutní míra vzájemné variabilita dvou statistických znaků $x; y$

$$s_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1}$$

Korelace - relativní míra vzájemné variabilita dvou statistických znaků $x; y$

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}$$


Základní vztahy

Autokovariance – absolutní míra proměnlivosti členů časové řady y posunutých o určitou hodnotu k .

$$c_k = \frac{\sum_{i=1}^{n-k} (y_i - \bar{y})(y_{i+k} - \bar{y})}{n - k - 1}$$

Autokorelace – relativní míra proměnlivosti členů časové řady y posunutých o určitou hodnotu k .

$$r_y(k) = \frac{c_k}{c_0} = \frac{c_k}{s_y^2}$$



Autokorelační funkce – hodnoty $r_y(k)$ pro $k=1,2,\dots,M$, kde $M < N/2$, N – délka řady

Autokorelační funkce

Autokorelační funkce (ACF) je potom závislost mezi hodnotami autokorelačního koeficientu a hodnotami posunu k .

Vyjadřuje se formou grafu – tzv. **korelogramu** (viz. obrázek). Na ose x jsou hodnoty lag (k), na ose y hodnoty autokorelačního koeficientu.

Hodnoty autokorelační funkce se pohybují v intervalu $-1, 1$.

ACF je vhodným nástrojem k posouzení, zda časová řada obsahuje cyklickou či periodickou složku a také zda je či není řadou náhodných čísel – tedy do jaké míry je možné ji extrapolovat (předpovídat).

