



SIGNÁLY A LINEÁRNÍ SYSTEMY



prof. Ing. Jiří Holčík, CSc.

holcik@iba.muni.cz, Kamenice 3, 4. patro, dv.č.424



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

XIV. ANALÝZA ČASOVÝCH ŘAD

ČASOVÁ ŘADA



WIKIPEDIA
The Free Encyclopedia

Časová řada jsou věcně a prostorově srovnatelná pozorování (dat), která jsou jednoznačně uspořádána z hlediska času ve směru minulost – přítomnost.

ČASOVÁ ŘADA




WIKIPEDIA
The Free Encyclopedia

Časová řada jsou věcně a prostorově srovnatelná pozorování (dat), která jsou jednoznačně uspořádána z hlediska času ve směru minulost – přítomnost.

Časová řada \equiv časově závislá posloupnost hodnot sledované veličiny v diskrétních časových okamžicích \equiv diskrétní signál


PŘÍKLADY



Zdroj: STEM, Trendy 2004/9 - 2008/03

Preference politických stran v ČR v období od 8/2004 do 3/2008


PŘÍKLADY



počty nezaměstnaných v Německu – 07.1975 – 09.1979 (po měsících)

PŘÍKLADY

POČTY SLUNEČNÍCH SKVRN



ČASOVÉ ŘADY – CO S NIMI?

- ☑ **stručný popis jejích vlastností** (pomocí několika některých souhrnných parametrů (statistik))



k popisu spíše funkce než jednoduchá hodnota, např.
klouzavý průměr než střední hodnota;
složky řady – trend, sezónní změny, pomalé a rychlé změny,
nepravidelné oscilace – **frekvenční analýza**

- ☑ **modelování průběhu**

- pochopení procesů způsobujících vznik dat;
- pragmatický nástroj pro splnění výše uvedených cílů
např. pomocí lineárních systémů – autoregresivní (AR),
integrační (I), s klouzavým průměrem (moving average –
MA)

ČASOVÉ ŘADY – CO S NIMI?

- ☑ **predikce budoucích hodnot** – velká část analytických metod pro časové řady;
(**Predikce** (z lat. prae-, před, a dicere, říkat) znamená **předpověď** či prognózu, tvrzení o tom, co se stane nebo nestane v budoucnosti. Na rozdíl od věštění nebo hádání se slovo predikce obvykle užívá pro odhady, opřené o vědeckou hypotézu nebo teorii. **srvn. forecasting**)
- ☑ **monitorování průběhu a detekce významných změn** - např. sledování funkce ledvin po transplantaci;

ČASOVÁ ŘADA

JAKÉ FENOMÉNY ROZPOZNÁVÁME

V PRŮBĚHU ČASOVÉ ŘADY?

- ✓ **trend**
- ✓ **oscilace**

ČASOVÁ ŘADA

JAKÉ FENOMÉNY ROZPOZNÁVÁME

V PRŮBĚHU ČASOVÉ ŘADY?

☑ trend

celkový, obecný sklon, směřování, vývojová tendance (ABZ.cz)

... $\{Y(t)\}$ je (nenáhodná, deterministická?) funkce $\mu(t) = E[Y(t)]$, kde $E[.]$ označuje očekávanou, resp. střední hodnotu;

ČASOVÁ ŘADA

JAKÉ FENOMÉNY ROZPOZNÁVÁME

V PRŮBĚHU ČASOVÉ ŘADY?

✓ **trend**

✓ **oscilace** –

→ kolik oscilačních složek obsahuje a jaké mají kmitočty?

ČASOVÁ ŘADA

JAKÉ FENOMÉNY ROZPOZNÁVÁME

V PRŮBĚHU ČASOVÉ ŘADY?

☑ **trend**

☑ **oscilace** –

- kolik oscilačních složek obsahuje a jaké mají kmitočty?
- jak často budeme odebírat vzorky?

ADITIVNÍ MODEL ČASOVÉ ŘADY

předpokládá, že hodnoty dané časové řady jsou realizacemi náhodné proměnné Y_n , která se skládá ze čtyř dílčích složek

$$Y_n = T_n + Z_n + S_n + R_n,$$

kde

T_n je (monotónní) funkce času (n, nT), kterou nazýváme **trend**;

Z_n reprezentuje nenáhodné (deterministické) dlouhodobé cyklické vlivy (ekonomické jevy, roční či déleodobější periodicitu – všechno je relativní,...);

složky T_n a Z_n se mnohdy slučují k vyjádření dlouhodobého chování časové řady

$$G_n = T_n + Z_n$$

ADITIVNÍ MODEL ČASOVÉ ŘADY

předpokládá, že hodnoty dané časové řady jsou realizacemi náhodné proměnné Y_n , která se skládá ze čtyř dílčích složek

$$Y_n = T_n + Z_n + S_n + R_n,$$

kde

T_n je (monotónní) funkce času (n, nT), kterou nazýváme **trend**;

Z_n reprezentuje nenáhodné (deterministické) dlouhodobé cyklické vlivy (déledobější nesezónní periodicitu – všechno je relativní, ...ekonomické jevy, doby ledové);

S_n popisuje nenáhodné (deterministické) krátkodobé cyklické (sezónní) vlivy;

R_n je náhodná veličina, která zahrnuje všechny náhodné odchylky od ideálního deterministického modelu

ZÁKLADNÍ KONCEPT

**REÁLNÝ
OBJEKT**

**PŘÍČINNÝ
DETERMINISTICKÝ VZTAH**

**HODNOTÍCÍ
VÝROK**

CÍL VŠECH MOŽNÝCH ANALÝZ

ODHALIT TEN PŘÍČINNÝ
DETERMINISTICKÝ VZTAH
NAVZDORY VŠEMU TOMU, CO
NÁM TO ODHALENÍ KAZÍ

ADITIVNÍ MODEL ČASOVÉ ŘADY

předpokládá, že hodnoty dané časové řady jsou realizacemi náhodné proměnné Y_n , která se skládá ze čtyř dílčích složek

$$Y_n = T_n + Z_n + S_n + R_n,$$

V dalším budeme předpokládat, že střední hodnota chybové proměnné R_n bude nulová, tj. že kladné i záporné odchylky od deterministického modelu jsou v průměru v rovnováze. (Toho lze vždycky dosáhnout šikovnou volbou jedné či více složek T_n , Z_n , nebo S_n .)

ADITIVNÍ MODEL ČASOVÉ ŘADY

předpokládá, že hodnoty dané časové řady jsou realizacemi náhodné proměnné Y_n , která se skládá ze čtyř dílčích složek

$$Y_n = T_n + Z_n + S_n + R_n,$$

Cílem analýzy časových řad je identifikovat a interpretovat jednotlivé složky časové řady.

MODELY TRENDU

☑ funkční

→ z nějakého hlediska (kritéria) optimální proložení experimentálních hodnot danou funkcí času – tedy když už známe, jakou funkční závislostí se sledovaná veličina řídí, tj. už známe řešení diferenční rovnice popisující dynamiku daného procesu

☑ dynamické

→ vytvoření modelu trendu lineární dynamickou soustavou, tj, známe jak popsat dynamiku procesu, ale neznáme řešení definiční diferenciální rovnice

NELINEÁRNÍ FUNKČNÍ MODELY TRENDU

předpokládejme pro zjednodušení aditivní model pouze

$$Y_n = T_n + R_n \text{ a } E(R_n) = 0,$$

pak $E(Y_n) = T_n = f(n)$

Obecně je funkce $f(n)$, jejíž funkční předpis známe, závislá na určitých parametrech, tj. $f(n; \beta_1, \dots, \beta_p)$. Parametry funkce odhadneme z množiny realizací y_n náhodné proměnné Y_n .

NELINEÁRNÍ FUNKČNÍ MODELY TRENDU



Standardním postupem, jak odhad lze spočítat, je odhad pomocí **nejmenších čtverců odchylky**

$$\sum_n (y_n - f(n, \hat{\beta}_1, \dots, \hat{\beta}_p))^2 = \min_{\beta_1, \dots, \beta_p} \sum_n (y_n - f(n, \beta_1, \dots, \beta_p))^2$$

Hodnoty $\hat{y}_n = f(n, \hat{\beta}_1, \dots, \hat{\beta}_p)$ pak slouží jako model chování mimo sledovaný interval (**dopředná, zpětná predikce**). Hodnoty rozdílů $y_n - \hat{y}_n$ nazýváme **rezidua**. Obsahují informaci o kvalitě datového modelu.

LOGISTICKÁ FUNKCE

$$f_{\log}(n) = f_{\log}(n, \beta_1, \beta_2, \beta_3) = \frac{\beta_3}{1 + \beta_2 \exp(-\beta_1 n)}, \quad n, \beta_1, \beta_2, \beta_3 \in \mathbb{R}$$



MITSCHERLICOVA FUNKCE

$$f_M(n) = f_M(n, \beta_1, \beta_2, \beta_3) = \beta_1 + \beta_2 \exp(\beta_3 n), \quad n \geq 0; \beta_1, \beta_2, \beta_3 \in \mathbb{R}$$

- ☑ typické použití pro dlouhodobý růst (pokles) v systému;
- ☑ počáteční hodnota je $f_M(0) = \beta_1 + \beta_2$;
- ☑ když je $\beta_3 < 0$, pak $\lim_{t \rightarrow \infty} f_M(n) = \beta_1$; β_1 je saturační hodnota stavu systému


GOMPERTZOVA FUNKCE

$$f_G(n) = f_G(n, \beta_1, \beta_2, \beta_3) = \exp(\beta_1 + \beta_2 \beta_3^n), \quad \beta_1, \beta_2 \in \mathbb{R}; \beta_3 \in (0, 1)$$

samozřejmě platí

$$\log(f_G(n)) = \beta_1 + \beta_2 \beta_3^n = \beta_1 + \beta_2 \exp(\log(\beta_3) \cdot n),$$

a tak $\log(f_G)$ je Mitscherlichovou funkcí s parametry β_1 , β_2 a $\log(\beta_3)$



ALOMETRICKÁ FUNKCE

$$f_a(n) = f_a(n, \beta_1, \beta_2) = \beta_2 n^{\beta_1}, \quad n \geq 0, \beta_1 \in \mathbb{R}, \beta_2 > 0$$

Protože

$$\log(f_a(n)) = \log(\beta_2) + \beta_1 \log(n), \quad n \geq 0,$$

můžeme použít lineární regresní model pro
logaritmická data $\log(y_n)$

$$\log(y_n) = \log(\beta_2) + \beta_1 \log(n) + \varepsilon_n, \quad n \geq 1,$$

kde ε_n reprezentuje chybovou proměnnou

ALOMETRICKÁ FUNKCE

Alometrie = studium proměnlivých proporcí rozměrů organismu, spojených se změnou jeho velikosti, a to buď v rámci individuálního růstu (a. ontogenetická), nebo ve srovnání s příbuznými organismy různých velikostí (a. fylogenetická)

Alometrická rovnice: nechť $y = mx^a$, kde x a y jsou změřené délky charakteristických částí těla. Tvar rovnice naznačuje nelineární závislost růstu. Předpokládáme $y = 0$ pro $x = 0$, je-li x celková délka.

Z toho plyne $\ln(y) = a \ln(x)$, kde $a =$ **alometrický koeficient** který odráží změny poměru délek x k délkám y .


Je-li $a = 1$, potom je y úměrné x a nedochází k žádné alometrii, y je isometrické vzhledem k x .

Je-li $a > 1$, roste y rychleji než x (pozitivní alometrie).

Je-li $a < 1$, roste y pomaleji než x (negativní alometrie).

Například u člověka roste hlava pomaleji než torzo.

ALOMETRICKÁ FUNKCE



LINEÁRNÍ FILTRACE ČASOVÝCH ŘAD

Předpokládejme

$$Y_n = T_n + S_n + R_n,$$

Cílem nechť je stanovení odhadů trendu (driftu) a sezónní složky (složek) \hat{T}_n a \hat{S}_n , které posléze odstraníme z časové řady $y_n - \hat{S}_n$, resp. $y_n - \hat{T}_n$, čímž řadu rozdělíme na „hladké“ deterministické složky a nepravidelnou fluktuační složku s nulovou střední hodnotou.

LINEÁRNÍ FILTRACE ČASOVÝCH ŘAD



Předpokládejme

$$Y_n = T_n + S_n + R_n,$$



Pokud vymyslíme filtr, který dokáže odhadnout (modelovat) průběh trendu, pak vymyšlený filtr představuje matematický model procesu, který je zdrojem trendové posloupnosti.

Pokud vymyslíme filtr, který dokáže odhadnout (modelovat) průběh sezónních oscilací, pak vymyšlený filtr představuje matematický model procesu, který je zdrojem sezónní posloupnosti.



JAK VYMYSLET TEN SPRÁVNÝ MODEL?



JAK VYMYSLĚT TEN SPRÁVNÝ MODEL?



JAK VYMYSLIT TEN SPRÁVNÝ MODEL?



Jaké známe signály s konstantním spektrem?

JAK VYMYSLET TEN SPRÁVNÝ MODEL?

Jaké známe signály s konstantním spektrem?

JAK VYMYSLIT TEN SPRÁVNÝ MODEL?

Jaké známe signály s konstantním spektrem?

- ☑ deterministický - jednotkový impuls;
- ☑ náhodný - bílý šum;

Chceme zkonstruovat takový filtr, které má, zjednodušeně, impulsní charakteristiku odpovídající modelovanému průběhu.

ODHAD TRENDU (DRIFTU)

pomalou se měnící složky



DOLNÍ PROPUST



(snadněji se realizuje pomocí MA filtrů)

Woldův dekompoziční teorém:



- jakýkoliv ARMA nebo MA proces může být jednoznačně reprezentován AR modelem max. ∞ řádu;
- jakýkoliv ARMA nebo AR proces lze reprezentovat MA modelem max. ∞ řádu;




je nám jedno, co použijeme za model, jen by měl mít co nejméně parametrů, které se snadno počítají





$$b=(1,1,1) \quad a=3$$





$$b=(1,1,1,1) \quad a=4$$





$$b=(1,1,1,1,1) \quad a=5$$



$$b=(1,1,1,1,1,1,1,1) \quad a=9$$





$$b=(1,2,2,2,1) \quad a=8$$





$$b=(1,2,3,2,1) \quad a=9$$

$$H(z)= (1+z^{-1}+z^{-2}).(1+z^{-1}+z^{-2})$$




$$b=(1,1,1) \quad a=3$$

$$H(z) = (1+z^{-1}+z^{-2})$$



$$b=(1,3,3,1) \quad a=8$$

$$H(z) = (1+z^{-1})^3$$



$$b=(1,1) \quad a=2$$
$$H(z)= (1+z^{-1})$$

ODHAD TRENDU (DRIFTU)

pomalu se měnící složky







DOLNÍ PROPUST

(snadněji se realizuje pomocí MA filtrů)

1. aby bylo zesílení filtru jednotkové, je třeba, aby $\sum_{i=1}^m |a_i| = 1$;
2. je třeba počítat průměr tak, aby nedocházelo ke zpoždění výstupních hodnot
– **jak toho dosáhnout?**

HRÁTKY S POČÁTEČNÍ FÁZÍ



HRÁTKY S POČÁTEČNÍ FÁZÍ

- ☑ ke zkreslení nedošlo, pokud fázová charakteristika byla lineární;
- ☑ lineární je tehdy, pokud je impulsní charakteristika symetrická

SKUPINOVÉ ZPOŽDĚNÍ


Záporná derivace fázové charakteristiky se nazývá skupinové zpoždění

$$\tau_g(\omega) = -\frac{d\varphi(\omega)}{d\omega}$$

Konstantní skupinové zpoždění znamená, že se všechny složky signálu kmitočtovém pásmu dostanou na výstup se stejným zpožděním.

Filtry řádu m s lineární fází mají skupinové zpoždění $m/2$ a filtrovaný signál je zpožděn o $m/2$ kroků.

PŘECHODOVÝ DĚJ




$$x(nT) = \{1, 2, 1, 2, 3, 1, 2\}$$

$$g(nT) = \{1/3, 1/3, 1/3\}$$

$$y(nT) = [x(nT) + x(nT-T) + x(nT-2T)]/3$$

PŘECHODOVÝ DĚJ




$$x(nT) = \{1, 2, 1, 2, 3, 1, 2\}$$

$$g(nT) = \{1/3, 1/3, 1/3\}$$

nulové počáteční podmínky: $x(0)=0$; $x(-T)=0$

$$y(nT) = [x(nT)+x(nT-T)+x(nT-2T)]/3$$

PŘECHODOVÝ DĚJ



$$x(nT) = \{1, 2, 1, 2, 3, 1, 2\}$$


$$g(nT) = \{1/3, 1/3, 1/3\}$$

počáteční podmínky určeny první hodnotou vstupu:

$$x(0)=1; x(-T)=1$$

$$y(nT) = [x(nT)+x(nT-T)+x(nT-2T)]/3$$

PŘECHODOVÝ DĚJ




$$x(nT) = \{1, 2, 1, 2, 3, 1, 2\}$$

$$g(nT) = \{1/3, 1/3, 1/3\}$$

výpočet vůči střední hodnotě impulsní odezvy:

$$y(nT) = [x(nT+T) + x(nT) + x(nT-T)]/3$$

PŘECHODOVÝ DĚJ



$$x(nT) = \{1, 2, 1, 2, 3, 1, 2\}$$

$$g(nT) = \{1/3, 1/3, 1/3\}$$

výpočet vůči střední hodnotě impulsní odezvy s nulovými počátečními a koncovými podmínkami

$$y(nT) = [x(nT+T) + x(nT) + x(nT-T)]/3$$

ODHAD TRENDU (DRIFTU)

pomalou se měnící složky



DOLNÍ PROPUST

(snadněji se realizuje pomocí MA filtrů)

1. aby bylo zesílení filtru jednotkové, je třeba, aby $\sum_{i=1}^m |a_i| = 1$;
2. je třeba počítat průměr tak, aby nedocházelo ke zpoždění výstupních hodnot
jak toho dosáhnout?

ODHAD TRENDU (DRIFTU)

DOLNÍ PROPUST

(snadněji se realizuje pomocí MA filtrů)

2. je třeba počítat průměr tak, aby nedocházelo ke zpoždění výstupních hodnot
 - počítat podle standardní diferenční rovnice o výsledek posunout o hodnotu skupinového zpoždění;
 - počítat vůči středu impulsní odezvy.

ODHAD TRENDU (DRIFTU)

DOLNÍ PROPUST

(snadněji se realizuje pomocí MA filtrů)

3. je třeba počítat s přechodným dějem o délce impulsní odezvy na začátku výstupu nebo o polovině délky impulsní odezvy na začátku a na konci

ODHAD TRENDU (DRIFTU)

DOLNÍ PROPUST

(snadněji se realizuje pomocí MA filtrů)

Jak odhadnout mezní frekvenci DP?

praktické pravidlo:

určíme oscilační složku o nejnižší frekvenci a mezní frekvenci DP pro odhad driftu stanovíme jako nejvyšší frekvenci propustného pásma filtru, který neovlivní oscilační složku

Příprava nových učebních materiálů pro obor Matematická biologie

je podporována projektem ESF
č. CZ.1.07/2.2.00/07.0318

„VÍCEOBOROVÁ INOVACE STUDIA MATEMATICKÉ BIOLOGIE“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ