

---

# **Kvantitativní analýza internetového provozu (3)**

Ladislav Lhotka  
*⟨lhotka@cesnet.cz⟩*

---

# Osnova přednášky

- Metody sběru dat – SNMP
- Časové řady
- Autokorelační funkce
- Časové řady s trendem a sezónními vlivy
- Predikce časových řad

# SNMP

Simple Network Management Protocol: RFC 3416 (verze 2)

Na straně serveru (managed device) se o komunikaci stará *agent* (softwarový démon).

Zabezpečení přístupu: *SNMP communities* (read-only, read-write)

Dva režimy:

1. Dotaz-odpověď: klient/manažer požádá agenta o určitou akci, ten ji provede (nebo také ne) a pošle odpověď.
2. *Trap*: asynchronní zpráva generovaná agentem, která manažera upozorňuje na změnu stavu zařízení nebo nějaký jev.


# Management objects

Každý objekt reprezentuje konkrétní údaj (konfigurační parametr, statistiku) nebo jejich posloupnost.

Soubor (databáze) objektů se nazývá *Management Information Base (MIB)*.

Objekty jsou dále tématicky členěny (podle typu zařízení nebo služby apod.) do *MIB modulů*.

# Struktura MIB



# Dotazy na data

U všech jsou jako parametry OID objektů, jejichž hodnota se žádá.

- GetRequest jedna nebo více hodnot MIB objektů
- GetNextRequest hodnota následujícího prvku posloupnosti
- GetBulkData umožňuje přenést celé posloupnosti

# Software pro SNMP

- Net-SNMP:  
*<http://www.net-snmp.org>*
- MRTG (Multi-Router Traffic Grapher):  
*<http://oss.oetiker.ch/mrtg/>*
- Nagios:  
*<http://www.nagios.org/>*

# Časové řady

Diskrétní časová řada je posloupnost pozorování jedné nebo více náhodných veličin uspořádaná v čase:

$$\{X_{t_1}, X_{t_2}, \dots, X_{t_n}\}$$

Předpokládáme ekvidistantní časový interval – řada se pak zapisuje

$$\{X_1, X_2, \dots, X_n\}$$

Proměnná  $X_n$  obvykle závisí na předchozí historii, např. opakované hody kostkou se nepovažují za časovou řadu.



# Značení

$\bar{X} = E(X)$  ... střední hodnota

$D(X)$  ... rozptyl

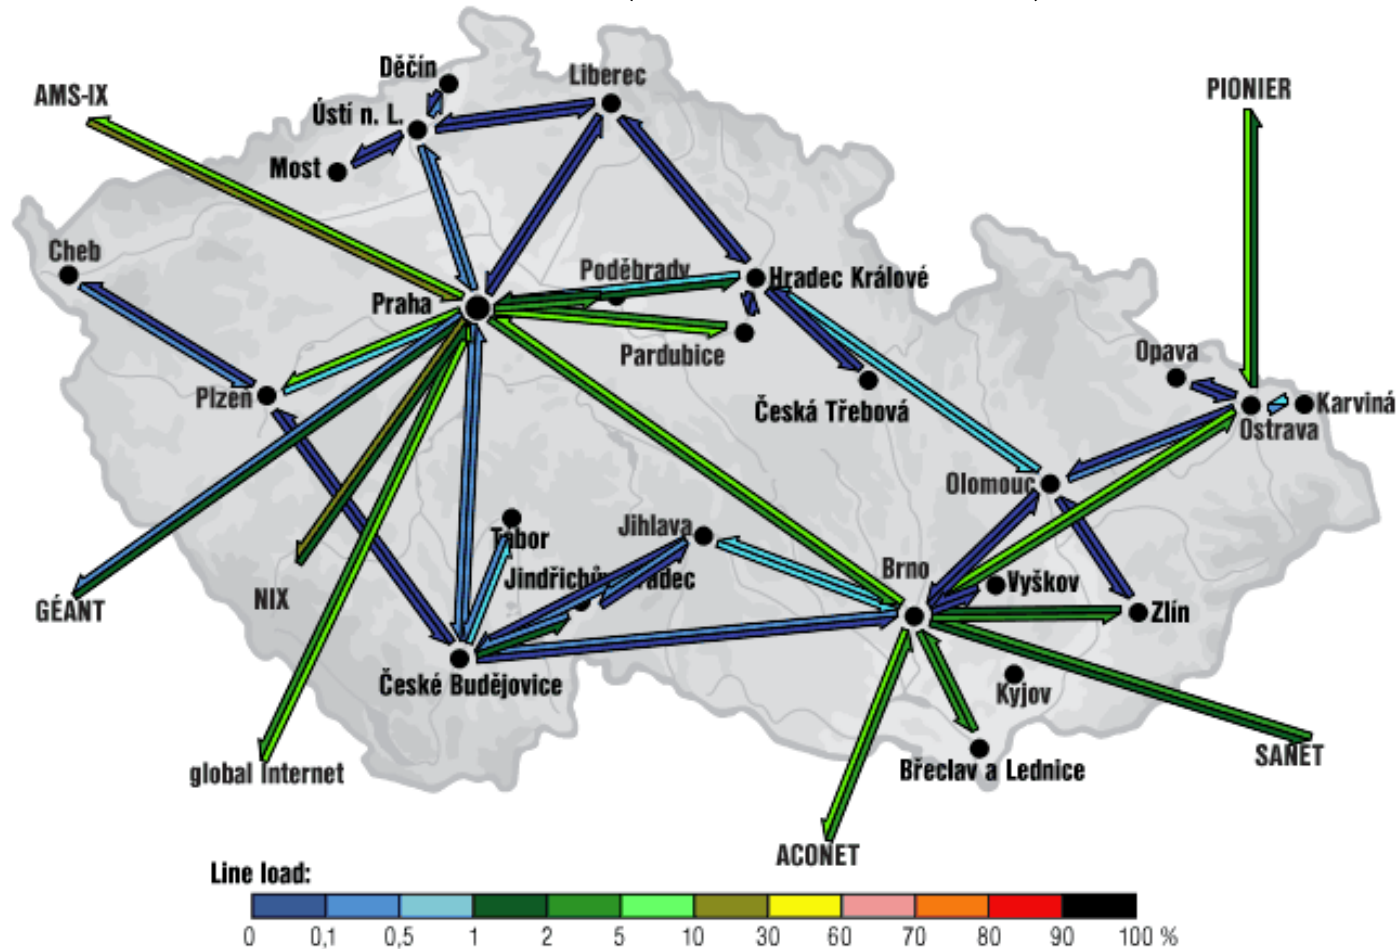
$\sigma(X)$  ... standardní odchylka

$C(X, Y)$  ... kovariance

$\rho(X, Y)$  ... koeficient korelace

# Objemové statistiky provozu

Vzorek z mezinárodního okruhu („global Internet“)



# telia-3roky.data


2005-06-29T20:00:00 – 2008-10-01T20:00:00,  $\Delta t = 1$  týden.

```
1120089600 357446623.982743
1120694400 193276988.836032
1121299200 218319212.625317
1121904000 214722634.92688
1122508800 230670664.3727
1123113600 220978686.182301
...
```

Levý sloupec: Unix time [s]

Pravý sloupec: průměrná hodnota za  $\langle t - \frac{\Delta t}{2}, t + \frac{\Delta t}{2} \rangle$  [bit/s]

## Public Internet Praha – 3 years



# Software pro časové řady

- R – *<http://www.r-project.org>*
- S-PLUS, SAS
- Mathematica, MAPLE

# Stacionarita časové řady

Stacionarita 1. řádu:  $E(X_t)$  nezávisí na  $t$ .

Stacionarita 2. řádu: Platí podmínka stacionarity 1. řádu a navíc  $C(X_t, X_{t+s})$  závisí pouze na  $s$ .

# Autokorelační funkce

Autokovarianční funkce pro řadu se stacionaritou 2. řádu:

$$\gamma_s = C(X_t, X_{t+s}) = E((X_t - \bar{X})(X_{t+s} - \bar{X}))$$

Autokorelační funkce

$$\rho_s = \frac{C(X_t, X_{t+s})}{\sigma(X_t)\sigma(X_{t+s})} = \frac{\gamma_k}{\gamma_0}$$

# Odhady ACF ze vzorku

$$\hat{\rho}_s = \frac{\sum_{t=1}^{n-s} (x_t - \bar{x})(x_{t+s} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2}$$



# Složky časové řady

$$X_t = T_t + S_t + e_t$$

$T_t$  ... trend

$S_t$  ... sezónní složka

$T_t$  ... trend

$e_t$  ... zbytek

# Separace složek

## Buys-Ballotova tabulka

	1	2	...	T	Celkem	Průměr
	$x_1$	$x_2$	...	$x_T$		
	$x_{T+1}$	$x_{T+2}$	...	$x_T$		
	$\vdots$	$\vdots$	$\vdots$	$\vdots$		
	$x_{n-T+1}$	$x_{n-T+2}$	...	$x_n$		
Celkem						
Průměr						

T je perioda

# Určení trendu – klouzavý průměr

$$T_t = \frac{1}{2a + 1} \sum_{i=-a}^a x_i$$

V *R* lze použít funkci `filter()`.

Pro naše data zkusíme klouzavý průměr přes 52 hodnot:

```
filter(bps, filter=rep(1/52,52))
```

# Stroje pracují za nás

Funkce `stl()` odhaduje z časové řady  $X_t$  trend  $T_t$  pomocí regresní metody LOESS a dopočítává sezónní složku  $S_t$  a zbytek  $e_t$ .

Ze seznamu hodnot je ale potřeba vytvořit objekt „time-series“:

```
rada.6 <- ts(bps, start=0, freq=6)
plot(stl(rada.6, s.window="periodic"))
```

# Predikce

Střední hodnota celé řady obvykle nefunguje.

Klouzavý průměr několika předchozích hodnot je lepší.

```
filter(bps, sides=1, filter=rep(1/3,3))
```

# Exponenciální vyhlazování

Předpovídaná hodnota

$$\hat{X}_{t+1} = \hat{a}_t$$

$$\begin{aligned}\hat{a}_t &= \alpha X_t + (1 - \alpha)\hat{X}_t \\ &= \alpha X_t + (1 - \alpha)\hat{a}_{t-1}\end{aligned}$$

Váha předchozích pozorování  $\alpha$  (smoothing parameter) se zmenšuje směrem do minulosti:

$$\hat{a}_t = \alpha X_t + \alpha(1 - \alpha)X_{t-1} + (1 - \alpha)^2 \hat{a}_{t-2} = \dots$$

Počáteční hodnotu můžeme nastavit např. takto:  $\hat{a}_0 = X_1$ .

# Holtova metoda – lineární trend

$$\hat{X}_{t+1} = \hat{a}_t + \hat{b}_t \Delta t$$

Zvolíme  $\Delta t$  za časovou jednotku.

$$\begin{aligned}\hat{a}_t &= \alpha X_t + (1 - \alpha)(\hat{a}_{t-1} + \hat{b}_{t-1}) \\ \hat{b}_t &= \beta(\hat{a}_t - \hat{a}_{t-1}) + (1 - \beta)\hat{b}_{t-1}\end{aligned}$$

# Wintersova metoda – sezónní variace

*Aditivní model*

$$\hat{X}_{t+1} = \hat{a}_t + \hat{b}_t \Delta t + \hat{s}_t$$

$$\hat{a}_t = \alpha X_t + (1 - \alpha)(\hat{a}_{t-1} + \hat{b}_{t-1})$$

$$\hat{b}_t = \beta(\hat{a}_t - \hat{a}_{t-1}) + (1 - \beta)\hat{b}_{t-1}$$

$$\hat{s}_t = \gamma(X_t - \hat{a}_t) + (1 - \gamma)\hat{s}_{t-p}$$



## *Multiplikativní model*

$$\hat{X}_{t+1} = (\hat{a}_t + \hat{b}_t \Delta t) \hat{s}_t$$

$$\hat{a}_t = \alpha X_t + (1 - \alpha)(\hat{a}_{t-1} + \hat{b}_{t-1})$$

$$\hat{b}_t = \beta(\hat{a}_t - \hat{a}_{t-1}) + (1 - \beta)\hat{b}_{t-1}$$

$$\hat{s}_t = \gamma(X_t/\hat{a}_t) + (1 - \gamma)\hat{s}_{t-p}$$