



PROGNOSTICKÉ METODY

P3
2009-03-05

Modely náhodných procházek:

- ✓ Platí: $Y_{t+1} = Y_t + u_{t+1}$
 $Y_t = Y_{t-1} + u_t$
 $E(u_t) = 0$
 $\text{Var}(u_t) = \sigma^2 < \infty$
 $\text{Cov}(u_t, u_s) = 0, t \neq s$
- ✓ První diference modelu náhodné procházky je stacionární.

 $I(0)$ 

$$\Delta Y_t = Y_t - Y_{t-1} = u_t$$

σ – rozptyl konstantní a konečný


✓ Vývoj v čase:

$$Y_0 = 0$$

$$Y_1 = Y_0 + u_1 = u_1$$

$$Y_2 = u_1 + u_2$$

$$Y_i = \sum_{i=1}^T u_i$$



✓ Prognóza Y_t :

$$E(Y_t) = E(Y_t | Y_{t-1}, Y_{t-2}, \dots, Y_0)$$

$$Y_{t+1} = Y_t + E(u_{t+1}) - \text{plyne, že } Y_t \text{ nezávisí na předchozích hodnotách}$$

$$Y_{t+1} = Y_t$$

$$Y_{t+h} = Y_t$$

Naše prognóza => stříška:

$$\hat{Y}_{t+1} = Y_t + E(u_{t+1})$$

$$\hat{Y}_{t+1} = Y_t$$

$$\hat{Y}_{t+h} = Y_t$$

$$t+h \Rightarrow h\sigma^2 n \dots \sqrt{h}$$

✓ Modifikace modelu náhodných procházek:

- Do modelu zahrneme trend
- Doplníme konstantu (delta): $Y_t = \delta + Y_{t-1} + u_t$
Rostoucí trend: $\delta > 0$
Klesající trend: $\delta < 0$
- Modifikace prognózy: $t+h$
- Krátkodobá: $\hat{Y}_{t+h} = \delta + Y_t$
- Dlouhodobá: $\hat{Y}_{t+h} = Y_t + h\delta$

✓ Chyba předpovědi E:

$$Y_{t+h} = Y_{t+h} - \hat{Y}_{t+h} = Y_t + h\delta + \sum_{i=1}^h u_i - Y_t - h\delta = \sum_{i=1}^h u_i$$

Lineárně roste s délkou prognostického horizontu h

Růst je funkcí, která je dána odmocninou.

Modely klouzavých průměrů (MA):

- ✓ Jedna z možností modelování dynamiky stacionárních časových řad



- ✓ Např. analýza vývoje změn cen akcií, kdy tato posloupnost změn cen s nulovým průměrem a konstantním rozptylem lze zapsat:
 - $Y_t = u_t$
 - u_t jsou identicky rozdělené náhodné složky, sériově nezkorelované. Odrážejí působení neočekávaných vlivů na cenu akcií, např. informace o finanční situaci podniku.
- ✓ Lze předpokládat, že všechny nové informace nejsou trhem absorbovány během 1 dne, proto změnu pro příští den lze vyjádřit jako: ...
- ✓ $Y_t = \beta_1 Y_{t-1} + u_t$
- ✓ Generování stochastickým procesem:
 $Y_t = u_t$
 u_t je charakteru bílého šumu s konstantním rozptylem: $E(u_t) = 0$; $\text{Var}(u_t) = \sigma^2 < \infty$
Vážený průměr jednotlivých hodnot u_t : $Y_t = u_t + \alpha_1 u_{t-1}$
- ✓ Proces klouzavých průměrů **MA(1)**: $Y_t = u_t + \alpha_1 u_{t-1}$
- ✓ **MA(q)**: $Y_t = \mu + u_t + \alpha_1 u_{t-1} + \alpha_2 u_{t-2} + \dots + \alpha_q u_{t-q}$
- ✓ **Vlastnosti pro MA(1)** pro model, kdy máme posun v hodnotě μ (lze zobecnit pro MA(q)):

$$Y_t = \mu + u_t + \alpha_1 u_{t-1}$$

Zajímá nás:

- **Průměr:** $E(Y_t) = \mu$
- **Rozptyl:** $\text{Var}(Y_t) = \gamma_0 = \sigma_u^2 (1 + \alpha_1^2)$
Kovariance: $\text{Cov}(Y_t, Y_{t+1}) = \gamma_1 = \sigma_u^2 \alpha_1$
případně: $\text{Cov}(Y_t, Y_{t-1}) = \gamma_1 = \sigma_u^2 \alpha_1$
- $\gamma_k = \sigma_u^2 \alpha_1$ pro $k = 1$
 $\gamma_k = 0$ pro $k > 1$
=> Model MA(1) má paměť pouze **jedno období**
Obecně model MA(q) má paměť **q období**.
- Máme rozptyl a kovarianci => můžeme převést na korelační koeficient a určit hodnoty korelační funkce. Z výše uvedeného plyne jak volit délku zpoždění q:

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{\alpha_1}{(1 + \alpha_1^2)} \text{ pro } k = 1$$

$$\rho_k = 0 \text{ pro } k > 1$$


Tedy:

$$\rho_k = \frac{\alpha_1}{1 + \alpha_1^2} \text{ pro } k = 1$$

$$\rho_k = 0 \text{ pro } k > 1$$

- **Graf – koreogram:**

2.



- $Y_t = u_t + \alpha_1 u_{t-1}$
 $u_t = Y_t - \alpha_1 u_{t-1}$
 $u_{t-1} = Y_{t-1} - \alpha_1 u_{t-2}$
 $u_t = Y_t - \alpha_1 (Y_{t-1} - \alpha_1 u_{t-2})$
 $u_t = Y_t - \alpha_1 Y_{t-1} + \alpha_1^2 u_{t-2}$
 α_1^i pro $i \rightarrow \infty$ je rovna 0 za předpokladu, že $|\alpha_1| < 1$ => **podmínka invertibility**
- **Invertibilita** znamená, že model lze vyjádřit pouze jedním způsobem, máme pouze jednu specifikaci.
 - Někdy model přímo napíše, že proces není invertibilní => lze to vyjádřit i jiným způsobem, ale my to nechceme.
 - Aby byl proces invertibilní, musí být korelační koeficient menší než 0,5.
 $|\rho_k| < 0,5$

**Autoregresní modely (AR):**

- ✓ Jiný přístup k modelování časové struktury stacionárních časových řad.
- ✓ Vyjádření y_t jako funkce několika předcházejících pozorování.

✓ **AR(p):**

$$AR(1) \rightarrow Y_t = \delta + \beta_1 Y_{t-1} + u_t$$

$$AR(p) \rightarrow Y_t = \delta + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + u_t$$

Od u_t očekáváme charakter bílého šumu a stejné vlastnosti průměru, rozptylu a kovariance.

✓ **Vlastnosti AR(1):**

$$Y_t = \delta + \beta_1 Y_{t-1} + u_t$$

$$\mu = \delta + \beta_1 \mu \Rightarrow \mu = \frac{\delta}{1 - \beta_1}$$

$$\bullet \text{ } Var(Y_t) = \gamma_0 = \frac{\sigma_u^2}{1 - \beta_1^2}$$

$$\bullet \text{ Kovariance: } \gamma_1 = \beta_1 \gamma_0$$


$$\gamma_2 = \beta_1^2 \gamma_0$$

...

$$\gamma_k = \beta_1^k \gamma_0$$

- Podmínka **stacionarity** časové řady je, že $|\beta_1| < 1$
Vyjde-li blízko 1, je časová řada nestacionární.

$$\Rightarrow \rho_k = \frac{\gamma_k}{\gamma_0} = \beta_1^k$$



Zde místo ACF použijeme pro identifikaci délky zpoždění PACF.

✓ **Identifikační body:**

- **MA** – určujeme na základě ACF
- **AR** – určujeme na základě PACF

✓ **Zobecnění pro AR(p):**

- $\mu = \frac{\delta}{1 - \beta_1 - \beta_2 - \dots - \beta_p} \Rightarrow$ podmínka stacionarity časové řady Y_t je dána (splněna), když

$$\beta_1 + \beta_2 + \dots + \beta_p < 1$$

$$\bullet \sum_{i=1}^p \beta_i < 1$$

$$\bullet \gamma_0 = \frac{\sigma_u^2}{1 - \beta_1 + \beta_2^2 + \dots + \beta_p^p}$$

$$\gamma_k = \beta_1 \gamma_{k-1} + \beta_2 \gamma_{k-2} + \dots + \beta_p \gamma_{k-p}$$

Apod.

$$\rho_k = \beta_1 \rho_{k-1} + \beta_2 \rho_{k-2} + \dots + \beta_p \rho_{k-p}$$