

## Trendová analýza - přímka a parabola

### Zadání příkladu:

Odhadněte parametry lineárního a kvadratického trendu u časové řady středního počtu obyvatelstva České republiky (ozn.  $P(t)$ ) od roku 1989 do roku 1998 a rozhodněte, který je vhodnější. Dále odhadněte pomocí vhodnějšího modelu počet obyvatel v roce 1999 a 2000. Hodnoty  $P(t)$  jsou uvedeny v tabulce 1.

Tab. 1 - Počet obyvatel ČR letech 1989-1998 v tisících - ozn.  $P_t$

Rok	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998
$P_t$	10362	10363	10309	10318	10331	10336	10331	10315	10304	10295

Zdroj dat: Český statistický úřad (ČSÚ)

### Vypracování příkladu

V trendové analýze je výstupem matematický model ČŘ, kde je sledovaná veličina  $y_t$  funkcí času  $t$  a náhodné složky  $\epsilon_t$ . To lze zapsat jako  $y_t = f(t, \epsilon_t)$ . Reálnou hodnotu  $y_t$  můžeme vyjádřit jako  $y_t = Y_t + \epsilon_t$ , kde  $Y_t = f(t)$  je tzv. teoretická (modelová) hodnota ukazatele. Klasický model dále rozkládá ČŘ na čtyři složky časového pohybu:

- Trendová složka  $T_t$  - dlouhodobá tendence ve vývoji ČŘ
- Sezónní složka  $S_t$  - pravidelně se opakující odchylka od trendu, periodicitu max. 1 rok
- Cyklická složka  $C_t$  - odchylka od trendu s periodicitou větší než 1 rok
- Náhodná složka  $\epsilon_t$  - náhodné odchylky, které nemají systematický charakter.

Podle způsobu rozkladu existují dva modely:

- **Aditivní**  $y_t = T_t + S_t + C_t + \epsilon_t$
- **Multiplikativní**  $y_t = T_t \cdot S_t \cdot C_t \cdot \epsilon_t$

V dalším postupu bude použit model aditivní.

### Přímka - lineární trend

Jedná se o jednoduchý, běžně používaný model ve tvaru:

$$T_t = \alpha_0 + \alpha_1 t \quad t = 1, \dots, n$$

Odhady parametrů  $\alpha_0$  a  $\alpha_1$  označíme  $a_0$  a  $a_1$ . Výpočet provedeme pomocí **metody nejmenších čtverců** známé z regresní analýzy. Odhad  $\hat{T}_t$  trendové složky  $T_t$  vyjádříme jako

$$\hat{T}_t = a_0 + a_1 t$$

Odhady spočteme podle vzorců analogických vzorcům z regrese, a to:

$$a_1 = \frac{\bar{ty}_t - \bar{t} \cdot \bar{y}_t}{\bar{t^2} - (\bar{t})^2}$$
$$a_0 = \bar{y}_t - a_1 \cdot \bar{t}$$

Připomeňme pouze, že parametr  $a_1$  se česky nazývá **směrnice**, anglicky **slope**, parametr  $a_0$  je potom **kvocient**, anglicky **intercept**.

### Parabola - kvadratický trend

Model trendu má tvar

$$T_t = \alpha_0 + \alpha_1 t + \alpha_2 t^2 \quad t = 1, \dots, n$$

Vztahy pro odhadu  $\alpha_0, \alpha_1, \alpha_2$  lze opět získat pomocí soustavy normálních rovnic, uvádět je zde však nebudeme.

### Program STATGRAPHICS Centurion XVII

V programu STATGRAPHICS je pro analýzu trendu ČR vytvořena funkcionality v menu *Forecast/User-Specified Model*. Do povinného pole **Data** je třeba zadat název proměnné, kde jsou hodnoty sledované veličiny  $y_t$ . Do nepovinného pole (**Time Indices:**) je možné zadat odpovídající hodnoty času. Po kliknutí na tlačítku OK se objeví další formulář *Model Specification Options*. Zde v rámci *Type* zvolíme **Linear Trend** a klikneme na tlačítko OK. V dalším formuláři *Tables and Graphs* přidáme tabulkou *Forecast Table* a potvrďme tlačítkem OK.

Pokud je třeba odhadnout parametry kvadratického trendu, je postup stejný, pouze zvolíme typ trendu **Quadratic Trend**.

Pro porovnání vhodnosti modelů slouží různé charakteristiky. Například MSE (Mean Squared Error), RMSE (Root Mean Squared Error) nebo MAE (Mean Absolute Error) nebo tzv. F-statistiky. MSE lze vypočítat podle vzorce

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

Statistiku F potom podle

$$F = \frac{\frac{\sum_{t=1}^n (\bar{y} - \hat{T}_t)^2}{p-1}}{\frac{\sum_{t=1}^n (y_t - \hat{T}_t)^2}{n-p}}$$

kde  $p$  je počet odhadovaných parametrů modelu. Platí, že čím je MSE nižší, tím je model vhodnější. U F-statistiky je tomu naopak - čím je její hodnota vyšší, tím je model vhodnější. Pokud **modely mají různý počet parametrů**, je nutné použít tzv. **upravený index determinace**  $I_{adj}^2$ , který nestejně počty parametrů zohledňuje - viz kapitola o regresní analýze.

Vypočítají se podle těchto vztahů

$$I^2 = \frac{\sum(\hat{T}_t - \bar{y})^2}{\sum(y_t - \bar{y})^2}$$
$$I_{adj}^2 = 1 - (1 - I^2) \frac{n - 1}{n - p}$$

Výsledky:

Nejprve vytvoříme graf (obr. 1) - postup viz téma 9, příklad 1.

Lineární trend

Odhady parametrů:  $a_0 = 10357,8$ ,  $a_1 = 5,71$ . Model má proto tvar  $T_t = 10357,8 - 5,7091t$ .

Nyní je nutné zkontrolovat, zdali jsou parametry modelu statisticky významné. V rámci *Analysis Summary* jsou v tabulce **Trend Model Summary** uvedeny odhady všech parametrů a příslušné hodnoty **P-value**. Pokud je hodnota P-value pro daný parametr nižší než zvolená hladina významnosti  $\alpha$  (ta bude vždy 5 %, pokud nebude stanoveno jinak), je daný parametr statisticky významný (nelze přijmout hypotézu, že je roven nule). Zde je  $P\text{-value}(a_0) = 0,00$ ,  $P\text{-value}(a_1) = 0,0118$ . Oba parametry jsou proto statisticky významné.

Výpočet předpovědí počtu obyvatel lze provést tak, že do vypočteného lineárního modelu dosadíme příslušnou hodnotu  $t$  a vypočteme  $\hat{Y}_t$ . Pro rok 1999 je  $t = 11$ , pro rok 2000 je  $t = 12$ , takže  $\hat{Y}_{11} = 10295$  a  $\hat{Y}_{12} = 10289$ . Ve STATGRAPHICS existuje ve výše zmíněné funkcionality *Forecast/User-Specified Model* tabulka **Forecast Table**, kde program vypočte předpověď pro libovolný časový okamžik. Požadovaný počet předpovědí lze nastavit ve formuláři Forecasting při zadávání proměnných pro analýzu (standardně 12).

Kvadratický trend

Odhady parametrů:  $a_0 = 10360,9$ ,  $a_1 = -7,25$ ,  $a_2 = 0,14$ .

Model má tvar  $T_t = 10360,9 - 7,25t + 0,14t^2$ .


Hodnoty P-value pro odhadované parametry jsou následující:

$P\text{-value}(a_0) = 0,00$ ,  $P\text{-value}(a_1) = 0,42$  a  $P\text{-value}(a_2) = 0,86$ . Z toho plyne, že je statisticky významný pouze kvocient, takže o kvadratickém trendu nemá smysl uvažovat.

## Interpretace výsledků

Výsledkem jsou dva modely. Lineární model  $T_t = 10357,8 - 5,7091t$  a kvadratický model  $T_t = 10360,9 - 7,25t + 0,14t^2$ . Testy významnosti regresních parametrů ukázaly, že u kvadratického modelu je významný pouze kvocient  $a_0$ , takže se fakticky nejedná o kvadratický trend. U lineárního modelu jsou naopak významné oba odhadované parametry. Pokud bychom měli interpretovat hodnotu  $a_1$ , je možné říci, že za každý rok počet obyvatel klesne přibližně o 5709. Předpovědi počtu obyvatel pro rok 1999 a 2000 jsou: 10295 a 10289. Pro srovnání, skutečný počet obyvatel ČR v uvedených letech činil 10283 a 10272 tis. obyvatel.

Obrázek 1: Počet obyvatel ČR v letech 1989-1998 v tis.



Zdroj: Údaje ČSÚ, vlastní zpracování