

# Dynamiczne modele liniowe w badaniach okresowych

mgr Kamil Wilak

Katedra Statystyki  
UE w Poznaniu

# O czym będzie mowa?

- ▶ badamy zmienność pewnego parametru w czasie w pewnej populacji
- ▶ co pewien okres losujemy próbę
- ▶ na podstawie próby szacujemy badany parametr
- ▶ precyzja oszacowania zależy od wielkości próby
- ▶ co, gdy mamy za małą próbę?

## Specyfikacja modelu

$$Y_t = \mathbf{F}'_t \boldsymbol{\theta}_t + \varepsilon_t \quad \varepsilon_t \sim N(0, \sigma_{\varepsilon,t}^2) \quad - \text{równanie pomiaru}$$

$$\boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\eta}_t \quad \boldsymbol{\eta}_t \sim N(\mathbf{0}, \mathbf{W}_t) \quad - \text{równanie przejścia}$$

gdzie

- ▶  $Y_t$  - obserwowana wartość szeregu czasowego
- ▶  $\boldsymbol{\theta}_t$  - nieobserwowany wektor parametrów stanu
- ▶  $\mathbf{F}_t$  i  $\mathbf{G}_t$  - wektor i macierz znanych współczynników liniowych
- ▶  $\varepsilon_t$  - zm. los. opisująca zmienność nieopisana przez parametry stanu / błąd obs.
- ▶  $\boldsymbol{\eta}_t$  - wektor losowy opisujący stratę w czasie informacji o wartości wektora  $\boldsymbol{\theta}_t$
- ▶  $\mathbf{W}_t$  - macierz kowariancji macierzy wektora losowego  $\boldsymbol{\eta}_t$

## Filtr Kalmana - filtrowanie

$D_t$  informacje dostępne w okresie  $t$ ,  $\theta_t | D_t \sim N(\mathbf{m}_t, \mathbf{C}_t)$

- ▶ prognoza 1 krok naprzód wektora  $\theta_{t+1}$  na podstawie informacji  $D_t$  ma rozkład normalny z parametrami:

$$\mathbf{a}_{t+1} = E(\theta_{t+1} | D_t) = \mathbf{G}_{t+1} \mathbf{m}_t$$

$$\mathbf{Z}_{t+1} = \text{Var}(\theta_{t+1} | D_t) = \mathbf{G}_{t+1} \mathbf{C}_t \mathbf{G}'_{t+1} + \mathbf{W}_{t+1}$$

- ▶ prognoza 1 krok naprzód  $Y_{t+1}$  na podstawie informacji  $D_t$  ma rozkład normalny z parametrami:

$$f_{t+1} = E(Y_{t+1} | D_t) = \mathbf{F}_{t+1} \mathbf{a}_t$$

$$\mathbf{Q}_t = \text{Var}(Y_{t+1} | D_t) = \mathbf{F}_{t+1} \mathbf{Z}_{t+1} \mathbf{F}'_{t+1} + \sigma_{\varepsilon, t+1}^2$$

## Filtr Kalmana - filtrowanie cd.

$D_{t+1} = \{D_t, Y_{t+1}\}$  informacje dostępne w okresie  $t$

- ▶ oszacowanie wektora  $\theta_{t+1}$  na podstawie informacji  $D_{t+1}$  ma rozkład normalny z parametrami:

$$\mathbf{m}_{t+1} = E(\theta_{t+1}|D_{t+1}) = \mathbf{a}_t + \mathbf{Z}_{t+1}\mathbf{F}'_{t+1}\mathbf{Q}_{t+1}^{-1}(Y_{t+1} - f_{t+1})$$

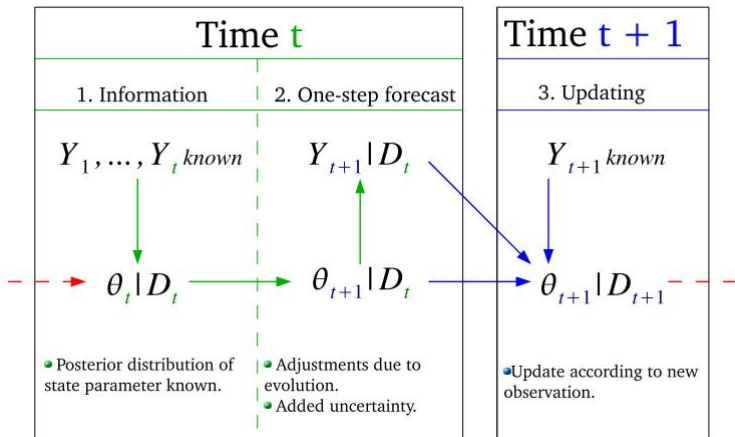
$$\mathbf{C}_{t+1} = \text{Var}(\theta_{t+1}|D_{t+1}) = \mathbf{Z}_{t+1} - \mathbf{Z}_{t+1}\mathbf{F}'_{t+1}\mathbf{Q}_{t+1}^{-1}\mathbf{F}_{t+1}\mathbf{Z}_{t+1}$$

Potrzebna jest macierz  $\mathbf{W}_t$

Można ją oszacować za pomocą Metody Największej Wiarygodności

# Dynamiczne modele liniowe

## Filtr Kalmana - filtrowanie cd.



Źródło: Solhjell Ida Kjersem [2009] *Bayesian Forecasting and Dynamic Models Applied to Strain Data from Gota River Bridge*

## Filtr Kalmana - wygładzanie

Jeżeli  $\theta_{t+1}|D_t \sim N(s_{t+1}, S_{t+1})$ , wtedy  $\theta_t|D_t \sim N(s_t, S_t)$ , gdzie:

$$s_t = m_t + \mathbf{C}_t \mathbf{G}'_{t+1} \mathbf{R}_{t+1}^{-1} (s_{t+1} - a_{t+1})$$

$$S_t = \mathbf{C}_t + \mathbf{C}_t \mathbf{G}'_{t+1} \mathbf{R}_{t+1}^{-1} (\mathbf{S}_{t+1} - \mathbf{R}_{t+1}) \mathbf{R}_{t+1}^{-1} \mathbf{G}_{t+1} \mathbf{C}_t$$

# Idea wykorzystania DLM w badaniach okresowych

Niech

- ▶  $Y_t$  - badany parametr populacji
- ▶  $\hat{Y}_t$  - oszacowanie bezpośrednie parametru populacji
- ▶  $e_t$  - błąd oszacowania,  $e_t \sim N(0, V_t)$ ,  $V_t = \text{Var}(\hat{Y}_t)$

Wtedy

$$\hat{Y}_t = Y_t + e_t \quad (1)$$

Założmy, że:

$$Y_t = \mathbf{F}'_t \boldsymbol{\theta}_t + \varepsilon_t \quad \varepsilon_t \sim N(0, \sigma_{\varepsilon,t}^2) \quad (2)$$

$$\boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\eta}_t \quad \boldsymbol{\eta}_t \sim N(\mathbf{0}, \mathbf{W}_t) \quad (3)$$

(2)-(3)  $\rightarrow$  (1), stąd

$$\hat{Y}_t = \mathbf{F}'_t \boldsymbol{\theta}_t + \varepsilon_t + e_t = \mathbf{F}'_t \boldsymbol{\theta}_t + v_t \quad v_t \sim N(0, \sigma_v^2 V_t), \quad \sigma_v^2 \approx 1 \quad (4)$$

$$\boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\eta}_t \quad \boldsymbol{\eta}_t \sim N(\mathbf{0}, \mathbf{W}_t) \quad (5)$$



# Przykład

## Dane

- ▶ dane jednostkowe z Badania Aktywności Ekonomicznej Ludności 2000-2005

## Populacja

- ▶ osoby biorące udział w BAEL-u

## Badany parametr

- ▶ miesięczna stopa bezrobocia  $Y_t = \frac{N_t^B}{N_t^A}$

$N_t^B$  - liczba osób bezrobotnych w miesiącu  $t$

$N_t^A$  - liczba osób aktywnych zawodowo w miesiącu  $t$

## Losowanie próby

- ▶ proste bez zwracania, wielkość próby - 500

## Oszacowanie bezpośrednie

$$\hat{Y}_t = \frac{n_t^B}{n_t^A}$$

$n_t^B$  - liczba osób bezrobotnych w próbie wylosowanej w miesiącu  $t$

$n_t^A$  - liczba osób aktywnych zawodowo w próbie wylosowanej w miesiącu  $t$

## Precyzja oszacowania bezpośredniego

$$V_t = \text{Var}(\hat{Y}_t) \approx \frac{(N_t - n_t)n_t}{N_t(n_t - 1)} \frac{n_t^B (n_t^A - n_t^B)}{(n_t^A)^3}$$

$N_t$  - wielkość populacji w miesiącu  $t$

$n_t$  - wielkość próby wylosowanej w miesiącu  $t$

$$\sqrt{\text{Var}(\hat{Y}_t)} \approx 0.023$$

$$\frac{\sqrt{\text{Var}(\hat{Y}_t)}}{\hat{Y}_t} \approx 0.125$$

# Przykład

$$\begin{aligned}\hat{Y}_t &= Y_t + e_t = & e_t &\sim N(0, \sigma_{e,t}^2) \\ &= L_t + S_t + \varepsilon_t + e_t = & \varepsilon_t &\sim N(0, \sigma_{\varepsilon,t}^2) \\ &= L_t + S_t + v_t & v_t &= e_t + \varepsilon_t \sim N(0, \sigma_v^2 V_t)\end{aligned}$$

$e_t$  - błąd oszacowania,  $\varepsilon_t$  - reszta modelu

$$\left. \begin{aligned}L_t &= L_{t-1} + R_{t-1} \\ R_t &= R_{t-1} + \omega_{R,t} \\ E(\omega_{R,t}) &= 0 \\ \text{Var}(\omega_{R,t}) &= \sigma_R^2\end{aligned} \right\} \text{trend lokalnie liniowy}$$

$$\left. \begin{aligned}S_t &= \sum_{j=1}^6 S_{t,j} \\ S_{t,j} &= \cos\left(\frac{j\pi}{6}\right) S_{t-1,j} + \sin\left(\frac{j\pi}{6}\right) S_{t-1,j}^* + \omega_{S,t,j} \\ S_{t,j}^* &= -\sin\left(\frac{j\pi}{6}\right) S_{t-1,j} + \cos\left(\frac{j\pi}{6}\right) S_{t-1,j}^* + \omega_{S,t,j}^* \\ E(\omega_{S,t,j}) &= E(\omega_{S,t,j}^*) = 0 \\ \text{Cov}(\omega_{S,t,j}, \omega_{S,t',j'}) &= \begin{cases} \sigma_{S,j}^2, & t = t', \quad j = j' \\ 0, & \text{wpp} \end{cases}\end{aligned} \right\} \text{sezonowość} \\ \text{trygonometryczna}$$

$$\left. \begin{aligned} \mathbf{F}_t &= (1, 0, 1, 0, 1, 0, 1, 0, 1, 0, 1, 0, 1) \\ \boldsymbol{\theta}_t &= (L_t, R_t, S_t, S_{t,1}^*, \dots, S_{t,6})^T \\ \mathbf{G}_t &= \text{blockdiag}(\mathbf{G}_t^R, \mathbf{G}_t^{S_1}, \dots, \mathbf{G}_t^{S_6}) \\ \mathbf{G}_t^R &= \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix} \\ \mathbf{G}_t^{S_j} &= \begin{pmatrix} \cos(j\pi/6) & \sin(j\pi/6) \\ -\sin(j\pi/6) & \cos(j\pi/6) \end{pmatrix} \\ \boldsymbol{\eta}_t &= (0, \omega_{R,t}, \omega_{S,t,1}, \omega_{S,t,1}^*, \dots, \omega_{S,t,6}) \end{aligned} \right\} \Rightarrow \begin{aligned} \hat{Y}_t &= \mathbf{Z}_t \boldsymbol{\theta}_t + v_t \\ \boldsymbol{\theta}_t &= \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\eta}_t \end{aligned}$$

## Pakiet *dlm*

- ▶ Giovanni Petris, Sonia Petrone, Partizia Campagnoli [2007/2011] *Dynamic Linear Models with R*
- ▶ Giovanni Petris [2010] *dlm - an R package for Bayesian analysis of Dynamic Linear Models*



Dziękuję za uwagę