

# Dodatek 1. Bayesowskie modele VAR

MODELOWANIE POLSKIEJ GOSPODARKI z R

# Formuła Bayesa

Formuła Bayesa:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Dlaczego:

$$P(A, B) = P(A|B)P(B) = P(B|A)P(A)$$

# Formuła Bayesa

Dla modelu ekonomicznego:

$$P(\Theta|Y) = \frac{P(Y|\Theta)P(\Theta)}{P(Y)}$$

$$P(\Theta|Y) \propto P(Y|\Theta)P(\Theta),$$

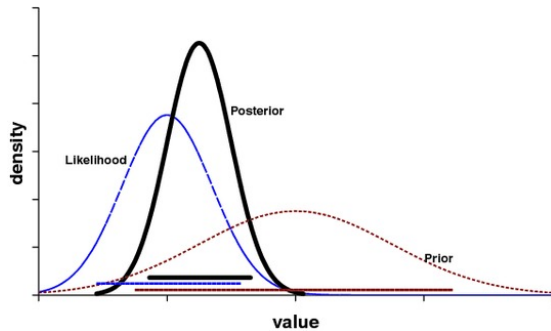
gdzie:

$P(\Theta)$  : rozkład a-priori dla parametru  $\Theta$

$P(Y|\Theta)$  : funkcja wiarygodności danych  $Y$

$P(\Theta|Y)$  : rozkład a-posteriori dla parametru  $\Theta$

# Ilustracja



# Rozkłady a-posteriori

- Istnieją klasy modeli oraz rozkładów a-priori dla których rozkład a-posteriori można uzyskać w sposób analityczny. W takim przypadku mówimy o sprzężonym rozkładzie a-priori (conjugate prior)
- W większości przypadków rozkład a-posteriori możemy uzyskać jedynie wykorzystując metody numeryczne (Gibbs sampling, Metropolis Hastings algorithm oraz inne)

# Sprzężony rozkład a-priori - model liniowy

Rozważmy model liniowy:

$$y_t = \beta x_t + \epsilon_t, \quad \epsilon_t \sim N(0, 1/h)$$

Rozkład a-priori typu Normal-Gamma:

$$\beta|h \sim N(\underline{\beta}, h^{-1}\underline{V}); \quad h \sim \Gamma(\underline{s}^{-2}, \underline{v}), \quad \beta, h \sim NG(\underline{\beta}, \underline{V}, \underline{s}^{-2}, \underline{v})$$

Oszacowania MNW:

$$\hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2}, \quad v = T - 1, \quad s^2 = \frac{\sum (y_i - \hat{\beta} x_i)^2}{v}$$

Rozkład a-posteriori:

$$\beta, h|y \sim NG(\bar{\beta}, \bar{V}, \bar{s}^{-2}, \bar{v}); \quad \beta|y \sim t(\bar{\beta}, \bar{s}^2 \bar{V}, \bar{v}),$$

gdzie:

$$\bar{V} = \frac{1}{\underline{V}^{-1} + \sum x_i^2}; \quad \bar{\beta} = \bar{V}(\underline{V}^{-1}\underline{\beta} + \hat{\beta} \sum x_i^2); \quad \bar{v} = \underline{v} + N$$
$$\bar{v}s^2 = \underline{v}s^2 + \frac{(\hat{\beta} - \underline{\beta})^2}{\underline{v} + (\sum x_i^2)^{-1}}$$

# Gibbs sampling

- Interesuje nas łączny rozkład  $p(\beta, \sigma^2 | y)$
- Znamy postać analityczną  $p(\beta | \sigma^2, y)$  oraz  $p(\sigma^2 | \beta, y)$
- Ustalamy wartości początkowe  $\beta_{(0)}$  i  $\sigma_{(0)}^2$
- Losujemy rekurencyjnie dla  $i = 1, 2, \dots, N + N_0$ :  $\beta_{(i)}$  z rozkładu  $p(\beta | \sigma_{(i-1)}^2, y)$  oraz  $\sigma_{(i)}^2$  z rozkładu  $p(\sigma^2 | \beta_{(i)}, y)$
- W rezultacie mamy  $N$  losowań z rozkładu łącznego  $p(\beta, \sigma^2 | y)$ , tj.  $(\beta_{(i)}, \sigma_{(i)}^2)$
- Usuwamy  $N_0$  początkowych losowań (burn-in sample)
- Możemy estymować  $g(\beta, \sigma^2 | y) \approx \frac{1}{N} \sum g(\beta_{(i)}, \sigma_{(i)}^2)$

# Przykład zastosowania Gibbs sampling - rozkład t-Studenta

- Chcemy obliczyć wartość oczekiwaną i wariancję zmiennej losowej  $X \sim t(\nu)$ , ale nie mamy generatora liczb z rozkładu t-Studenta (teoretyczne wartości to 0 i  $\nu/(\nu - 2)$ )
- Wiemy, że jeżeli  $\sigma^2 \sim Inv\chi^2(\nu)$  oraz  $X|\sigma^2 \sim N(0, \sigma^2)$  to  $X \sim t(\nu)$
- Dla  $i = 1, 2, \dots, N$  losujemy  $\sigma_{(i)}^2$  z rozkładu  $Inv\chi^2(\nu)$  oraz  $X_{(i)}$  z rozkładu  $N(0, \sigma_{(i)}^2)$ .
- Szacujemy wartość oczekiwaną jako  $E(X) = \frac{1}{N} \sum X_{(i)}$ , zaś wariancję jako  $Var(X) = \frac{1}{N} \sum X_{(i)}^2$ .



## Przykład zastosowania Gibbs sampling - rozkład t-Studenta

```
v      = 10;                # liczba stopni swobody
N      = 1000;             # liczba ciągnięć
sig2   = NULL;
X      = NULL;

for (i in 1:N){
  Y     = rchisq(1, v);     # losujemy z rozkładu chi2(v)
  sig2 = c(sig2,v/Y);
  X     = c(X , rnorm(1,0,sqrt(sig2[i])));
}

> sum(X)/N                  # teoretyczna wartość 0
0.03229785

> sum(X^2)/N                # teoretyczna wartość v/(v-2)
1.287174
```

# Algorytm Metropolis-Hastings

- Chcemy obliczyć momenty rozkładu a-posteriori  $\theta|y$  (który nie jest standardowy)
- Startujemy w  $\theta_{(0)}$  dla którego liczymy  $p(\theta_{(0)}|y)$
- Kolejne ciągnięcia z rozkładu a-posteriori dla  $i = 1, 2, \dots, N + N_0$  liczymy rekurencyjnie
- Ustalamy  $\theta^* = \theta_{(i)} + \delta\epsilon$ , gdzie  $\delta$  to stała skalująca, zaś  $\epsilon \sim N(0, \Sigma)$ .
- Losujemy liczbę  $u$  z rozkładu jednostajnego  $U(0, 1)$
- Jeżeli  $\frac{p(\theta^*)}{p(\theta_{(i)})} > u$  ustalamy  $\theta_{(i+1)} = \theta^*$ . W przeciwnym przypadku  $\theta_{(i+1)} = \theta_{(i)}$
- Usuwamy  $N_0$  początkowych obserwacji (burn-in sample)
- Możemy estymować  $g(\beta, \sigma^2|y) \approx \frac{1}{N} \sum g(\beta_{(i)}, \sigma_{(i)}^2)$

# Model BVAR z rozkładem apriori Littermana

- Zapis modelu VAR:

$$y_t = [A_0 \quad A_1 \quad \dots \quad A_p] [1 \quad y'_{t-1} \quad \dots \quad y'_{t-p}]' + \epsilon_t = Ax_t + \epsilon_t$$

- Rozkład a-priori dla elementów macierzy  $A_p$ :

$$\underline{a}_{ij}^{(p)} = \begin{cases} 1 & \text{dla } i = j, p = 1 \\ 0 & \text{dla pozostałych} \end{cases}$$

$$\underline{\sigma}_{ij}^{(p)} = \lambda_1 \times p^{-\lambda_3} \times \sigma_i / \sigma_j$$

$$\underline{\sigma}_i^{(0)} = \lambda_4 \times \sigma_i$$

- Oznaczenia:

$\lambda_1$ : Overall tightness

$\lambda_3$ : Lag decay

$\lambda_4$ : constant tightness

$\sigma_i$ : Wariancja reszt modelu AR( $P$ ) dla zmiennej  $y_{it}$

# BVAR - Litterman prior

- Zapis dla  $i$ -tego równania (każde równanie jest szacowane oddzielnie)

$$y_{it} = a_i' x_t + \epsilon_{it}$$

- Oszacowanie MNW:

$$\hat{a}_i = (X'X)^{-1}X'y, \quad \sigma_{\epsilon_i}^2 = 1/T \sum e_t^2$$

- Rozkład a-priori:

$$a_i \sim N(\underline{a}_i, \underline{\Sigma}_i)$$

- Rozkład a-posteriori:

$$a_i|y \sim N(\bar{a}_i, \bar{\Sigma}_i),$$

gdzie:

$$\bar{\Sigma}_i = (\underline{\Sigma}_i^{-1} + \sigma_{\epsilon_i}^{-2} X'X)^{-1}$$

$$\bar{a}_i = \bar{\Sigma}_i (\underline{\Sigma}_i^{-1} \underline{a}_i + \sigma_{\epsilon_i}^{-2} X'y)$$

# BVAR - Litterman prior dla $N = 2$ i $P = 2$

Rozkład a-priori dla dwuwymiarowego modelu VAR(2):

$$a_1 = \begin{bmatrix} a_1^{(0)} \\ a_1^{(1)} \\ a_{11}^{(1)} \\ a_{12}^{(1)} \\ a_1^{(2)} \\ a_{11}^{(2)} \\ a_{12}^{(2)} \end{bmatrix} \sim N \left( \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} (\lambda_4 \sigma_1)^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & (\lambda_1)^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & (\lambda_1 \times \sigma_1 / \sigma_2)^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & (\lambda_1 \times 2^{-\lambda_3})^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & (\lambda_1 \times 2^{-\lambda_3} \times \sigma_1 / \sigma_2)^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & (\lambda_1 \times 2^{-\lambda_3} \times \sigma_1 / \sigma_2)^2 \end{bmatrix} \right)$$

$$a_2 = \begin{bmatrix} a_2^{(0)} \\ a_2^{(1)} \\ a_{21}^{(1)} \\ a_{22}^{(1)} \\ a_2^{(2)} \\ a_{21}^{(2)} \\ a_{22}^{(2)} \end{bmatrix} \sim N \left( \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} (\lambda_4 \sigma_2)^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & (\lambda_1 \times \sigma_2 / \sigma_1)^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & (\lambda_1)^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & (\lambda_1 \times 2^{-\lambda_3} \times \sigma_2 / \sigma_1)^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & (\lambda_1 \times 2^{-\lambda_3})^2 \end{bmatrix} \right)$$

# BVAR - Sims-Zha prior

- W przypadku rozkładu a-priori Littermana parametry każdego równania są estymowane oddzielnie i nie bierze się pod uwagę korelacji składnika losowego  $\Sigma$
- Rozkład a-priori zaproponowany w opracowaniu Sims-Zha (1998) uwzględnia występowanie zależności między składnikami losowymi
- Autorzy proponują rozkład a-priori typu Normal-Wishart, który w połączeniu z funkcją wiarygodności dla wielowymiarowego rozkładu losowego daje rozkład a-posteriori typu Normal-Wishart

# BVAR - Sims-Zha prior

Zapiszmy model VAR:

$$y_t = Ax_t + \epsilon_t, \epsilon_t \sim N(0, \Sigma)$$

Jako:

$$y_t = \begin{bmatrix} x_t' & 0 & \dots & 0 \\ 0 & x_t' & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & x_t' \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \dots \\ a_N \end{bmatrix} + \epsilon_t = Z_t a + \epsilon_t, \epsilon_t \sim N(0, \Sigma)$$

Oszacowania MNW dla parametru  $a$ :

$$\hat{a} = \left( \sum_{t=1}^T Z_t' Z_t \right)^{-1} \left( \sum_{t=1}^T Z_t' y_t \right)$$

# BVAR - Sims-Zha prior

$$y_t = Z_t a + \epsilon_t, \epsilon_t \sim N(0, \Sigma)$$

Rozkład a-priori:

$$\Sigma \sim \text{InvW}(\underline{\Sigma}, \underline{\nu}) \text{ oraz } a|\Sigma \sim N(\underline{a}, \underline{V}),$$

$$\underline{\Sigma} = \text{diag}((\sigma_1/\lambda_0)^2, (\sigma_2/\lambda_0)^2, \dots, (\sigma_N/\lambda_0)^2)$$

$$\underline{\nu} = N + 2$$

$$\underline{a}_{ij}^{(p)} = 1 \text{ dla } i = j, p = 1 (0 \text{ dla pozostałych})$$

$$\underline{V} = \Omega \otimes \Sigma$$

$$\Omega_{ij}^{(p)} = \left( \frac{\lambda_0 \lambda_1}{\sigma_i p \lambda_3} \right)^2 \text{ oraz } \Omega_i^{(0)} = \lambda_0 \lambda_4$$

$\sigma_i$  : odchylenie std. reszt modelu AR( $P$ ) dla  $y_{it}$

$\lambda_0$  : overall tightness

$\lambda_1$  : tightness around AR coefficients

$\lambda_4$  : tightness around intercept

$\lambda_3$  : lag decay



# BVAR - Sims-Zha prior

Dodatkowo, Sims-Zha zaproponowali dodanie do macierzy obserwacji zmiennych zero-jedynkowych postaci (dla dwuwymiarowego modelu VAR(2)):

„Sum of coefficients” dummies:

$$[\mu_5 \bar{y}_1 \quad 0]' \text{ oraz } [0 \quad \mu_5 \bar{y}_1 \quad 0 \quad \mu_5 \bar{y}_1 \quad 0]'$$

$$[0 \quad \mu_5 \bar{y}_2]' \text{ oraz } [0 \quad 0 \quad \mu_5 \bar{y}_2 \quad 0 \quad \mu_5 \bar{y}_2]'$$

„Cointegration” dummy:

$$[\mu_6 \bar{y}_1 \quad \mu_6 \bar{y}_2] \text{ oraz } [\mu_6 \quad \mu_6 \bar{y}_1 \quad \mu_6 \bar{y}_2 \quad \mu_6 \bar{y}_1 \quad \mu_6 \bar{y}_2]'$$

# BVAR - Sims-Zha prior

Model z dummies:  $\tilde{y}_t = \tilde{Z}_t \mathbf{a} + \tilde{\epsilon}_t, \tilde{\epsilon}_t \sim N(0, \Sigma)$

Rozkład a-priori:  $\Sigma \sim \text{InvW}(\underline{\Sigma}, \underline{\nu})$  oraz  $\mathbf{a} | \Sigma \sim N(\underline{\mathbf{a}}, \underline{V})$

Oszacowanie MNW:  $\hat{\mathbf{a}} = (\sum_{t=1}^{\tilde{T}} \tilde{Z}_t' \tilde{Z}_t)^{-1} (\sum_{t=1}^{\tilde{T}} \tilde{Z}_t' \tilde{y}_t)$

Rozkład a-posteriori:  $\Sigma | y \sim \text{InvW}(\bar{\Sigma}, \bar{\nu})$  oraz  $\mathbf{a} | \Sigma, y \sim N(\bar{\mathbf{a}}, \bar{V})$

Zależności:

$$\bar{\Sigma} = \underline{\Sigma} + \sum_{t=1}^{\tilde{T}} (\tilde{y}_t - \tilde{Z}_t \hat{\mathbf{a}})(\tilde{y}_t - \tilde{Z}_t \hat{\mathbf{a}})'$$

$$\bar{\nu} = \underline{\nu} + \tilde{T}$$

$$\bar{\mathbf{a}} = \bar{V}(\underline{V}^{-1} \underline{\mathbf{a}} + \sum_{t=1}^{\tilde{T}} \tilde{Z}_t \Sigma^{-1} \tilde{y}_t)$$

$$\bar{V} = (\underline{V}^{-1} + \sum_{t=1}^{\tilde{T}} \tilde{Z}_t \Sigma^{-1} \tilde{Z}_t')^{-1}$$