

## BAYESIÁNSKÁ ANALÝZA – CVIČENÍ 5

Toto cvičení je založeno na znalosti šesté kapitoly z učebnice Koop (2003): *Bayesian econometrics*, případně na odpovídající kapitole podkladového učebního textu *Bayesiánská analýza*.

### Co bude náplní cvičení?

- ⌚ Odhad a aposteriorní analýza normálního nelineárního regresního modelu s obecnou kovarianční maticí, a to s využitím reálných dat.
- ⌚ Příklad na heteroskedasticitu využívající efektivnější kód než původní empirická ilustrace.
- ⌚ Příklad na autokorelaci a SUR model odpovídající empirické ilustraci z Koop (2003).

### Zadání příkladů

1. Předpokládejme, že spotřeba energie v čase roste s tím, jak narůstá populace a její důchod, a naopak klesá s růstem cen energií. Využijte roční data pro Spojené státy od roku 1960 do roku 1985 a odhadněte regresní model závislosti distribuované energie na čase, ceně a důchodu domácností. Datový soubor je EX64.dat, výchozí m-files postupně energya.m, energyb.m a energyc.m. Model je definována jako

$$Q = \beta_1 + \beta_2 \cdot YEAR + \beta_3 \cdot P + \beta_4 \cdot INC$$

kde  $Q$  je logaritmus množství dodané energie ( $10^{15} BTU$ ),  $YEAR$  nabývá hodnoty 1 v roce 1960 a 26 v roce 1960,  $P$  je logaritmus ceny energií (za jednotku, v dolarech roku 1975) a  $INC$  je logaritmus důchodu na jednu domácnost (v dolarech roku 1975, !v původním datovém souboru není logaritmován!).

Vyjděte z nezávislé normální-gama apriorní hustoty pro odhadované parametry. Výsledky metodou nejmenších čtverců prezentované Pindyckem a Rubinfeldem<sup>1</sup> (Příklad 6.4, strana 158) jsou ( $t$ -statistiky jsou uvedeny v závorkách):

$$\begin{array}{rccccccccc} \hat{Q} & = & -36.48 & + & 0.18YEAR & - & .67P & + & .55INC \\ & & (-1.98) & & (1.76) & & (-8.99) & & (2.03) \\ R^2 & = & .970 & & & & & & s = .032 \end{array}$$

Řešte tento příklad bez předpokladu heteroskedasticity a potom i s předpokladem známé kovarianční maticí a neznámé kovarianční maticí (náhodné chyby budou z  $t$ -rozdělení). V případě známé kovarianční maticí testujte (porovnáním modelů) případ, neexistence heteroskedasticity. Inspiraci pro postup můžete hledat v Koop (2003), využijte rovněž i hotové skripty z předchozích cvičení (nebo se jimi alespoň inspirujte). V ramci regrese pro prvky obecné kovarianční matice  $\Omega$  můžete využít i neinformativní prior  $\alpha \propto 1$ , v tom případě nelze počítat Bayesův faktor (nedává správné výsledky) pro testování hypotéz zahrnující  $\alpha$ .

2. Proveďte bayesiánskou analýzu v rámci příkladu (empirické ilustrace) z Koop (2003), příklad (6.5.3). Tento regresní model se snaží vysvětlit procento výher baseballového týmu New York Yankees v každém roce (v období 1903 až 1999) v závislosti na statistikách charakterizujících ofenzivní a defenzivní výkonnost tohoto týmu. Datový soubor je yankees.txt, výchozí m-files pak chapter06c\_noauto.m, chapter06c.m a zcela obecný chapter06c\_expand.m. Vysvětlovanou proměnnou je winning percentage ( $PCT$ ) v roce  $t$ , tedy  $PCT = wins/(wins+losses)$ . Vysvětlujícími veličinami jsou on-base percentage ( $OBP$ ), team slugging average ( $SLG$ ) a team earned run average ( $ERA$ ) vše za rok  $t$ . Bližší vysvětlení těchto veličin je obsaženo v souboru baseball\_statistics.pdf.

Předpokládáme v modelu autokorelaci náhodných složek. Vzhledem k tomu, že subjektivní určení apriorních hustot je obtížné, použijte neinformativní apriorní hustotu pro  $\beta$  a zvolte tedy  $\underline{V}^{-1} = 0_{k \times k}$ . Stejně tak užijte neinformativní apriorní hustotu pro  $h$  nastavením  $\underline{\nu} = 0$ . Totuo volbou se stává hodnota  $\underline{\beta}$  a  $\underline{s}^{-2}$  irrelevantní.

<sup>1</sup>Pindyck, Rubinfeld (1997) Econometric models and economic forecast. 4. vydání

Spočítejte Savage-Dickey density ratio porovnávající modely s  $\rho_j = 0$  pro  $j = 1, \dots, p$  vzhledem k neomezenému modelu. To vyžaduje formulaci informativní apriorní hustoty pro  $\rho$ , vhodnou volbou je zde  $\underline{\rho} = 0$  a  $V_\rho = c * I_p$ . V rámci analýzy citlivosti apriorních hustot pak volíme různá  $c$ .

Koop ukazuje, že Bayesův faktor a HPDI nepodpořily hypotézu o autokorelaci vyššího řádu než je jedna. Můžete tudíž rovnou zvolit  $p = 1$ , což bude znamenat, že stacionární oblast je pro  $|\rho_1| < 0$ . Zkuste však odhadnout model i s předpokladem autokorelace vyššího řádu a samozřejmě neopomeňte odhad bez předpokladu autokorelace (pro srovnání výsledků).

3. Proveděte bayesiánskou analýzu v rámci příkladu (empirické ilustrace) z Koop (2003), příklad (6.6.4). Tento regresní model se snaží vysvětlit procento výher baseballového týmu New York Yankees a Red Sox v každém roce (v období 1903 až 1999) v závislosti na statistikách charakterizujících ofenzivní a defenzivní výkonnost tohoto týmu. Datový soubor je `yankees.txt` a `yankees.txt`, výchozí m-file pak `chapter06d.m`. Vysvětlovanou proměnnou je winning percentage (*PCT*) v roce  $t$ , tedy  $PCT = wins/(wins + losses)$ . Vysvětlujícími veličinami jsou on-base percentage (*OBP*), team slugging average (*SLG*) a team earned run average (*ERA*) vše za rok  $t$ . Bližší vysvětlení těchto veličin je obsaženo v souboru `baseball_statistics.pdf`. Model bereme jako model zdánlivě nesouvisejících regresí.

Vzhledem k tomu, že subjektivní určení apriorních hustot je obtížné, použijme neinformativní apriorní hustotu pro  $\beta$  a zvolme tedy  $\underline{\beta} = 0_k$ ,  $\underline{V}^{-1} = 4I_k$  a  $\underline{H}^{-1} = 0_{2 \times 2}$ . Na základě výsledků korelace náhodných složek mezi oběma rovinicemi pak můžeme rozhodnout, jestli bylo vůbec nutné pracovat se SUR modelem.